

Gheorghe Cârțină

Gheorghe Grigoraș

***Tehnici de Inteligență Artificială
în Electroenergetică***



Gheorghe CÂRȚINĂ

Gheorghe GRIGORAȘ

TEHNICI DE INTELIGENȚA ARTIFICIALĂ ÎN ELECTROENERGETICĂ





EDITURA SOCIETĂȚII ABSOLVENȚILOR DE
ELECTROTEHNICĂ DIN IAȘI (SETIS)
B-dul D. Mangeron nr. 53, Iași, România
Tel: 0232-278680 / int. 1196
E-mail: setis@ee.tuiasi.ro

Referenți științifici:

Prof. univ. dr. ing. **Mircea Eremia**
Universitatea "Politehnica" - București
Prof. univ. dr. ing. **Virgil Alexandrescu**
Universitatea Tehnică "Gh. Asachi" - Iași

Tehnoredactare și grafica computerizată:

Gheorghe Grigoras
Gheorghe Cârțina

Coperta:

Gabriel Urma

ISBN: 973-86764-4-4

Descrierea CIP a Bibliotecii Nationale
GHEORGHE, CÂRȚINĂ
**TEHNICI DE INTELIGENȚA ARTIFICIALĂ ÎN
ELECTROENERGETICĂ** / Gheorghe Cârțină, Gheorghe Grigoraș
Editura SETIS, 2004
212 pag., 21 cm
ISBN: 973-86764-4-4

*"So far as the laws of mathematics refer to reality,
they are not certain. And so far as they are certain,
they do not refer to reality."*

Albert Einstein

From the beginning, civilization has been structured, in large part, around the concept of work... Now, for the first time, human labor is being systematically eliminated from the production process. Intelligent machines are replacing human being in countless tasks, forcing millions of blue and white collar workers into unemployment lines, or worse still, breadlines.

The term Artificial Intelligence was coined at first AI conference, held at Dartmouth College in 1956. Today, when scientists talk of AI, they generally mean "the art of creating machines that perform functions which require intelligence when performed by people".

Although most computer scientists would hesitate to put AI on the same par as the creation of the universe and the appearance of life on earth, they are nearly unanimous in their belief that by sometime in the next century this powerful new technological force will be able to out-think the average human mind.

Some of the new thinking machines can recognize casual speech, carry on meaningful conversations, and even solicit additional information upon which to make decisions, provide recommendations, and answer questions.

Many computer scientists look to the day when intelligent machines will be sophisticated enough to evolve on their own-creating, in effect, their own consciousness-without the need of consultant intervention.

In the future, scientists hope to humanize their machines, creating lifelike computer-generated images of human faces that can converse with the user from a video display screen. By the end of the first half of the twenty-first century, scientists believe it will be possible to create life-size holographic images of computer-generated human being capable of interacting with real human being in real time and spaces.

Jeremy Rifkin, The End of the Work, 1995

CUPRINS

PREFAȚĂ	11
1. MODELAREA PRIN TEHNICI DE INTELIGENȚĂ ARTIFICIALĂ (IA) ÎN CONDUCEREA PROCESELOR ENERGETICE	13
1.1. Aspecte generale	13
1.2. Problema definirii inteligenței	14
1.3. Conducerea proceselor energetice	17
1.4. Utilizarea modelării fuzzy	18
1.5. Perspective privind IA	21
Bibliografie	23
2. PRINCIPIILE INTELIGENȚEI ARTIFICIALE	27
2.1. Rețele neuronale artificiale (RNA)	28
2.1.1. Caracteristicile și limitele RNA	28
2.1.2. Modele și structuri de RNA	30
2.1.3. Perceptronul multistrat (MLP)	33
2.1.4. Aspecte privind utilizarea RNA	39
2.1.5. Perspectivele RNA	42
2.2. Sisteme expert (SE)	43
2.2.1. Ce este un sistem expert ?	43
2.2.2. Inteligența artificială și Sistemele expert	44
2.2.3. Reprezentarea și procesarea cunoștințelor în SE	46
2.2.4. Dezvoltarea și aplicațiile SE	50
2.3. Logica fuzzy (LF)	53
2.3.1. Mulțimi fuzzy și Logica fuzzy	53
2.3.2. Alegerea funcției de apartenență	57
2.3.3. Operații cu numere (mulțimi) fuzzy	59
2.4. Algoritmi genetici (AG)	63
2.4.1. Limitele metodelor tradiționale de optimizare	63
2.4.2. Algoritmii genetici	64
Bibliografie	69
3. TEHNICI DE GRUPARE SPAȚIALĂ ÎN OPTIMIZĂRI	73
3.1. Aspecte generale privind gruparea spațială	73
3.1.1. Etapele procesului de grupare spațială	74
3.1.2. Dificultățile utilizatorului și rolul expertizei	75
3.1.3. Metode de grupare spațială	76
3.2. Estimarea pierderilor de putere/energie în rețelele de distribuție	82
3.2.1. Aspecte generale privind pierderile de putere/energie	82
3.2.2. Algoritmul de grupare a fiderilor de MT	83
3.2.3. Modelarea încărcării rețelilor de distribuție prin tehnici fuzzy	87
3.2.4. Estimarea pierderilor de putere/energie folosind Logica fuzzy	89
3.3. Determinarea benzilor optime de reglare a tensiunii în rețelele de transport	92

3.3.1. Determinarea profilurilor de sarcină în rețelele de 110 kV	92
3.3.2. Algoritmul de grupare a profilurilor de sarcină	95
3.3.3. Aspecte generale privind reglajul tensiune-putere reactivă	99
3.3.4. Modelul matematic de optimizare	101
3.3.5. Rezultate numerice	102
Bibliografie	107
4. PROBLEMA CORELAȚIEI ÎN MODELAREA FUZZY	109
4.1. Analiza de regresie și corelație	109
4.1.1. Analiza legăturilor statistice	109
4.1.2. Modele de regresie cu două variabile	112
4.1.3. Măsurarea intensității legăturii dintre două variabile	113
4.2. Corelarea sarcinilor în modelarea fuzzy	115
4.2.1. Modelul fuzzy cu sarcini necorelate	116
4.2.2. Necesitatea corelării puterilor în modelele fuzzy	117
4.3. Estimarea puterilor la vârful de sarcină	119
4.3.1. Folosirea corelației fuzzy	119
4.3.2. Estimarea puterilor la vârful de sarcină în rețelele de 110 kV	122
4.3.3. Estimarea puterilor la vârful de sarcină în rețelele de distribuție	127
4.3.4. Îmbunătățirea estimării puterilor prin tehnici de grupare spațială	132
4.4. Analiza regimurilor rețelelor electrice cu modele fuzzy	139
4.4.1. Modelarea fuzzy în analiza regimurilor rețelelor de transport	139
4.4.2. Modelarea fuzzy în analiza regimurilor rețelelor de distribuție	142
Bibliografie	146
5. OPTIMIZĂRI MULTICRITERIALE ÎN ELECTROENERGETICĂ	149
5.1. Aspecte generale privind optimizarea multicriterială	149
5.2. Criterii de comparare a variantelor	153
5.2.1. Siguranța în alimentare	153
5.2.2. Impactul asupra mediului	172
5.3. Utilizarea tehnicilor GIS (Geographic Information Systems)	174
5.3.1. Sistemul GIS	174
5.3.2. Rolul sistemului GIS în planificarea și exploatarea optimală	178
5.3.3. Integrarea și procesarea documentelor de tip GIS în Matlab	179
5.4. Coordonarea mijloacelor de reglaj prin tehnici neuro-fuzzy	187
5.4.1. Importanța coordonării mijloacelor de reglaj	187
5.4.2. Coordonarea mijloacelor de reglaj prin tehnici neuro-fuzzy	188
5.5. Optimizarea amplasării surselor de putere reactivă	192
5.5.1. Formularea problemei de optimizare	192
5.5.2. Modelul matematic	194
5.5.3. Metoda Algoritmilor genetici	202
Bibliografie	204
ANEXA 1	210
ANEXA 2	211

CONTENTS

PREFACE	12
1. MODELING BY ARTIFICIAL INTELLIGENCE TECHNIQUES (AI) IN THE POWER SYSTEM PROCESS CONTROL	13
1.1. General Aspects	13
1.2. Intelligence Definition Problem	14
1.3. Power System Process Control	17
1.4. Using of the Fuzzy Modeling	18
1.5. AI Future Trends	21
References	23
2. ARTIFICIAL INTELLIGENCE PRINCIPLES	27
2.1. Artificial Neural Networks (ANN)	28
2.1.1. Features and Limitations of the ANN	28
2.1.2. Models and Structures of the ANN	30
2.1.3. Multilayer Perceptron (MLP)	33
2.1.4. Using ANN in Real World Applications	39
2.1.5. ANN Future Trends	42
2.2. Expert System (ES)	43
2.2.1. What is an Expert System?	43
2.2.2. Artificial Intelligence and Expert System	44
2.2.3. Knowledge Representation and Processing	46
2.2.4. Expert System Design and Applications	50
2.3. Fuzzy Logic (FL)	53
2.3.1. Fuzzy Set and Fuzzy Logic	53
2.3.2. Membership Function Selection	57
2.3.3. Fuzzy Numbers and Fuzzy Sets Operations	59
2.4. Genetic Algorithms (GA)	63
2.4.1. Limits of the Classic Optimization Methods	63
2.4.2. Genetic Algorithms	64
References	69
3. CLUSTERING TECHNIQUES IN OPTIMIZATIONS	73
3.1. Clustering General Aspects	73
3.1.1. Clustering Steps	74
3.1.2. The User's Dilemma and the Role of the Expertise	75
3.1.3. Clustering Methods	76
3.2. Power/Energy Losses Estimation in the Distribution Networks	82
3.2.1. General Aspects Regarding the Power/Energy Losses	82
3.2.2. MV Feeders Clustering Algorithm	83
3.2.3. Distribution Networks Loading Modeling using Fuzzy Techniques	87
3.2.4. Power/Energy Losses Estimation using Fuzzy Logic	89
3.3. Determination of the Voltage Optimal Control Bands in the Transmission Networks	92

3.3.1. Determination of the Load Profiles in the 110 kV Networks	92
3.3.2. Load Profiles Clustering Algorithm	95
3.3.3. General Aspects Regarding the Voltage-Reactive Power Control	99
3.3.4. Optimization Mathematical Model	101
3.3.5. Numerical Results	102
References	107
4. CORRELATION PROBLEM IN FUZZY MODELING	109
4.1. Regression and Correlation Analysis	109
4.1.1. Statistical Relationship Analysis	109
4.1.2. Regression Models with Two Variables	112
4.1.3. Intensity Relationship Measurement among Two Variables	113
4.2. Loads Correlation in Fuzzy Modeling	115
4.2.1. Fuzzy Model with Uncorrelated Loads	116
4.2.2. Powers Correlation Necessity in Fuzzy Modeling	117
4.3. Powers Estimation at the Peak Load	119
4.3.1. Using of the Fuzzy Correlation	119
4.3.2. Powers Estimation at the Peak Load in the 110 kV Networks	122
4.3.3. Powers Estimation at the Peak Load in the Distribution Networks	127
4.3.4. Improvement of the Powers Estimation with Clustering Techniques	132
4.4. Load Flow Analysis in the Electric Networks with Fuzzy Models	139
4.4.1. Fuzzy Modeling in Load Flow Analysis of the Transmission Networks ..	139
4.4.2. Fuzzy Modeling in Load Flow Analysis of the Distribution Networks ..	142
References	146
5. MULTICRITERION OPTIMIZATIONS IN POWER SYSTEMS	149
5.1. General Aspects	149
5.2. Comparison Criteria of the Solution	153
5.2.1. Supply Safety Criterion	153
5.2.2. Impact on the Environment	172
5.3. Using of the GIS (Geographic Information Systems)	174
5.3.1. GIS System	174
5.3.2. Role of the GIS in Optimal Planning and Operation	178
5.3.3. Integrating and Processing GIS Documents by MatLab	179
5.4. VQ Controllers Coordination by Neural-Fuzzy Techniques	187
5.4.1. Importance of the VQ Controllers Coordination	187
5.4.2. VQ Controllers Coordination using Neural-Fuzzy Techniques	188
5.5. Optimization of the Reactive Sources Placement	192
5.5.1. Optimization Problem Formulation	192
5.5.2. Mathematic Model	194
5.5.3. Genetic Algorithms Method	202
References	204
ANNEX 1	210
ANNEX 2	211

PREFAȚĂ

Sistemul electroenergetic este unul dintre cele mai mari și mai complexe sisteme din era tehnologiei. Conducerea acestui sistem va deveni din ce în ce mai dificilă datorită rolului acestuia, rol ce continuă să crească odată cu procesul de dereglementare.

În cadrul sistemului electroenergetic se întâlnesc numeroase probleme, deosebit de importante, cum ar fi: optimizarea circulațiilor de putere, optimizarea încărcării centralelor electrice, luarea deciziilor în piețele dereglementate etc.

În ultimii ani cercetarea din domeniul exploatarei și planificării optime a sistemelor electroenergetice este în plină dezvoltare. În literatura de specialitate au fost publicate numeroase lucrări și rapoarte ce se referă la: modele noi de îmbunătățire a performanțelor tehnicii de calcul, algoritmi noi de optimizare, nivelul din ce în ce mai mare de incertitudini introdus de procesul de dereglementare etc. În vederea obținerii soluției optime au fost folosite diferite metode, bazate, în special, pe utilizarea tehnicilor clasice (programarea liniară, programarea dinamică, programarea neliniară etc) și tehnicilor de Inteligență artificială (programarea evolutivă).

Această carte este dedicată, în esență, folosirii tehnicilor de Inteligență artificială în optimizarea exploatarei și planificării sistemelor electroenergetice, tehnici care sînt prezentate într-o manieră practică. În scopul unei modelări și conduceri mai bune a proceselor din sistemul electroenergetic prin mijloace ce aparțin Inteligenței artificiale, în carte sînt prezentate tehnicile de grupare spațială. Gruparea spațială constă în organizarea unor colecții de modele (de obicei reprezentate de un vector al măsurătorilor sau de un punct în spațiul multidimensional) în grupe bazate pe similitudini. Cei mai mulți dintre algoritmi descriși sînt prezentați într-o manieră detaliată, permițînd implementarea simplă a acestora. Această manieră este destinată familiarizării cititorului cu unele aspecte importante ale aplicării Inteligenței artificiale: cum acționează algoritmi respectivi, modul lor de convergență, dificultățile care pot fi întâlnite și remediile posibile.

Autorii

PREFACE

The electric power system is one of the largest and most complex machines of the technological age. Managing this system will become increasingly difficult as overall loading continues to grow with deregulation.

In power systems there are many very interesting problems as Optimal power flow, Optimal unit commitment, Decision-Making in deregulated markets, and so on.

In the last few years, research in the area of optimal operation and planning of power systems is in expansion. Many papers and reports about new models have been published in the technical literature due mostly to the improvement of the computer power availability, new optimization algorithms, and greater uncertainty level introduced by the power sector deregulation. Several methods have been proposed to obtain the optimum solution, mostly using classical optimization techniques and intelligent techniques like linear programming, dynamic programming, nonlinear programming, mixed integer programming, evolutionary programming and so on.

This book is essentially devoted to using of the Artificial Intelligence techniques in operation and planning optimization of power systems, which are exposed in a tutorial way. For a better modeling and controlling power process by means of the Artificial Intelligence, the book presents the clustering techniques. Cluster analysis is the organization of a collection patterns (usually represented as a vector of measurements, or a point in multidimensional space) into clusters based on similarity. Most of the algorithms described in the book are explained in a detailed manner, allowing straightforward implementation. This level of detail is intended to familiarize the reader with some of the crucial questions of numerical application of Artificial Intelligence: how algorithms operate, why they converge, difficulties that may be encountered and their possible remedies.

The Authors

CAPITOLUL 1

MODELAREA PRIN TEHNICI DE INTELIGENȚĂ ARTIFICIALĂ (IA) ÎN CONDUCEREA PROCESELOR ENERGETICE

1.1. Aspecte generale

Istoria civilizațiilor a fost și este strâns legată de câțiva factori de bază, dintre care dezvoltarea și progresul sînt dintre cei mai importanți. La rîndul lor, acești factori depind de diverse forme de resurse, printre care și cele energetice, dependență care pentru viitor se anunță si mai determinantă.

Astăzi, factori de decizie din lumea întreagă, organisme guvernamentale sau științifice se întreabă cu îndreptățire care va fi viitorul civilizației, care vor fi energiile acesteia în perioadele următoare și cum va trebui să arate educația în anii ce vin.

Răspunsul nu este ușor de găsit în asemenea probleme, pentru că multe s-au schimbat și se vor mai schimba, față de perioadele anterioare și, chiar, față de secolul douăzeci, de care nu de mult ne-am despărțit.

S-a schimbat și contextul general. Dintre aparițiile cele mai importante menționăm Noua Tehnologie a Informației (NTI), tehnicile de Inteligență artificială, multe alte tehnologii ultraperformante.

NTI se referă la principalele tehnici de comunicație, bazate pe Internet. Peisajul informatic mondial a fost bulversat în ultimii ani de generalizarea Internetului. NTI afectează și procesele educaționale și de învățare și continuă să schimbe, în mod drastic, natura muncii, a societăților, elaborarea și implementarea deciziilor. Într-o lume în care sînt posibile conferințe virtuale, simulări de tot felul, în care se poate cu greu discerne realitatea de virtual, procesul educațional nu mai poate utiliza doar metodele tradiționale.

Orice conducere a unui proces industrial, manuală sau automată, se bazează pe un model al procesului supus comenzii. Acest model poate fi mai mult sau mai puțin elaborat. În funcție de modelare, putem avea în vedere diferite metode de conducere. De exemplu, în conducerea manuală, operatorul acționează în funcție de

reprezentarea mentală a comportării procesului, comportare pe care operatorul o construiește plecând de la experiența sa.

Noțiunea de modelare este esența tehnicii moderne de conducere a proceselor în general și a celor energetice, în particular. Punerea la punct a unui procedeu de conducere trece prin punerea la punct a unui model, care să mărească partea de anticipație în calculul acțiunilor și să limiteze rolul feed-backului. Din acest punct de vedere este foarte interesant să precizăm că un model nu reprezintă realitatea, el nu este decât o proiecție a acesteia în spațiul simplificat, ale cărui dimensiuni au fost alese în funcție de problema ce trebuie rezolvată. În sine, un model nu este nici bun, nici rău, el este numai mai bine sau mai puțin bine adaptat anticipațiilor necesare preciziei de conducere vizată.

Dacă noțiunea de model este omniprezentă în conducerea modernă, manierele de realizare sînt diverse. Pînă nu demult, noțiunea de modelare a fost sinonimă cu sisteme de ecuații diferențiale, funcții de transfer etc. Introducerea calculatoarelor a fost percepută ca un formidabil mijloc de a aprofunda aspectul matematic și de a împinge mai departe complexitatea modelelor și a procesului de conducere.

Mai tîrziu au fost introduse în conducerea proceselor alte tipuri de modelare, mai simbolice, care se bazează mai mult pe o cunoaștere empirică și externă procesului, decât pe analiza matematică a funcționării sale interne. Modelarea simbolică este foarte familiară omului. Este suficient să ne gîndim la modul în care conducem un autoturism pe timp de ceață, noaptea. În fiecare moment interpolăm situațiile recunoscute înregistrate în creierul nostru, pentru a găsi acțiunile adaptate la situația curentă. În trecere, se poate remarca că acest lucru nu necesită o capacitate de procesare foarte ridicată pentru creierul uman.

Dintre modelele bazate pe tehnicile IA, cele mai folosite sînt modelele neuro-fuzzy. Modelul Rețelelor neuronale artificiale (RNA), privit ca o cutie neagră, vizează a construi modelul **“Situație - Acțiune”**, fără a recurge la definirea explicită a acestor corespondențe. Aportul RNA, prin proprietatea lor de **aproximator universal**, este de a permite depășirea limitelor metodelor statistice tradiționale (regresii liniare, neliniare etc), pentru a stabili o relație neliniară multivariabilă între intrările și ieșirile procesului. RNA este deci o cutie neagră, care are la intrare un număr de variabile, aduse de la traductoarele unui proces, iar la ieșire, acțiuni de comandă posibile asupra procesului. Aceasta prezintă avantajul realizării unui dispozitiv de conducere fără cunoștințe a priori asupra funcțiunii interne a procesului.

1.2. Problema definirii inteligenței

Pentru a defini Inteligența artificială, este nevoie să definim mai întîi inteligența. Sîntem în cazul unui termen complex și intrat în obișnuință, pentru care încercarea unei definiții precise poate fi foarte dificilă. Totuși este importantă, măcar

trasarea unei granițe în jurul acestui concept, necesară pentru precizarea unor elemente de IA.

Cercetătorii din domeniul IA au căutat să definească inteligența dintr-o perspectivă care să permită apoi definirea IA. O asemenea definiție este următoarea: **“Un sistem se poate considera inteligent, dacă se poate adapta singur la noi situații, are capacitatea de a raționa, adică de a înțelege legăturile dintre fapte, de a descoperi înțelesuri și de a recunoaște adevărul. Un asemenea sistem poate să învețe, adică să-și îmbunătățească performanțele pe baza experienței”**. Altă definiție apreciază că inteligența apare ca un amalgam cu multe proprietăți de reprezentare și prelucrare a informației. În această formă, definiția ne arată dificultatea precizării acestei noțiuni, dar și apropierea de domeniul calculatoarelor.

În opoziție cu aceste încercări, există o altă concepție, potrivit căreia nu se poate da o definiție inteligenței, deoarece aceasta nu poate fi izolată și definită ca o noțiune de sine stătător, iar inteligența poate fi dedusă numai din comportarea oamenilor. La rândul ei, comportarea (inteligentă) este relativă, iar o manifestare inteligentă luată izolat nu asigură o comportare inteligentă în general.

Pe de altă parte, nu există un singur tip de inteligență, care să stea la baza reușitei în viață. Revoluția cognitivă, dominantă după anii 1960, s-a bazat pe stocarea informațiilor, iar inteligența (rațională) a fost socotită ca fiind rezultatul unui proces la rece al faptelor, calculatorul reprezentând o seducție în acest sens. Există o Inteligență emoțională (IE) și se referă la capacitatea de a stăpîni impulsurile, de a regla stările de spirit, de a fi stăruitor, de a spera [Goleman 2001].

Spre deosebire de inteligența rațională (măsurată prin IQ - Intelligent Quotient care are o istorie de aproape 100 de ani de cercetări aplicate pe sute de mii de oameni), IE este un concept relativ nou. Nimeni nu poate spune exact în ce măsură variază de la o persoană la alta, de-a lungul vieții. Uneori IE poate fi mai puternică decât cea rațională, iar competențele emoționale de importanță crucială pot fi dobândite și îmbunătățite în etapa copilăriei, prin educarea controlului impulsurilor.

Emoția se referă la un sentiment și la gândurile pe care acestea le antrenează, la stări psihologice și biologice, la măsura în care sîntem inclinați să acționăm. Există sute de emoții de toate tipurile, cu diverse variații, schimbări și nuanțe. De asemenea, există și emoții mult mai subtile decât cuvintele care le-ar putea defini.

Cercetătorii continuă să discute în contradictoriu care sînt emoțiile care ar putea fi considerate primare – ceea ce în domeniul culorilor primare ar corespunde culorilor roșu, galben și albastru, din care pot fi generate toate combinațiile posibile – sau dacă măcar există asemenea emoții primare. Unii teoreticieni propun încrengăturile primare: mînia, tristețea, frica, bucuria, iubirea, dezgustul și rușinea.

Aceste două minți, cea rațională și cea emoțională, acționează de cele mai multe ori în strînsă armonie, împletindu-și căile atît de diferite pentru a ne conduce în viață. În acest echilibru emoțiile alimentează și informează operațiile minții raționale, iar aceasta rafinează și uneori se opune emoțiilor.

Modul cum s-a dezvoltat creierul dă o enormă putere centrilor emoționali, care pot influența mult funcționarea restului, inclusiv a centrilor gândirii raționale.

Felul cum reușim în viață este determinat de cele două creiere, cel al rațiunii și cel al emoțiilor.

Intelectul nu poate funcționa la capacitatea maximă fără IE. Versiunea științifică că ar exista o viață mintală fără influențe emoționale se schimbă pe măsură ce se recunoaște rolul sentimentelor în gândire. Indepărtarea sentimentelor din gândire înseamnă a nu recunoaște că acestea dau savoare vieții, dar și momentelor de criză, care influențează măsura în care sînt prelucrate informațiile. De exemplu, dispozițiile și stările proaste pot conduce la raționamente nu tocmai fericite.

Pentru a simplifica oarecum lucrurile să menționăm abordarea dată de Bloom, care identifică trei domenii de abilități: cognitiv, afectiv și psihomotor. Domeniul cognitiv este rezervat abilităților raționale, cel afectiv se ocupă de cele emoționale, iar domeniul psihomotor, de cele fizice. Abilitățile cognitive ar fi de domeniul ingineriei [Chowdhury 04].

Domeniul cognitiv are 6 nivele ierarhice, Fig. 1.1 [Chowdhury 04]. Abilitățile cerute diferitelor competențe sînt prezentate în Fig. 1.2. Cercetările au arătat că în cazul studenților, de exemplu, peste 95% din lotul testat se mulțumesc cu treapta a întâia, memorarea informației.




Fig. 1.1. Domeniile cognitive în taxonomia lui Bloom




Fig. 1.2. Abilitățile corespunzătoare diferitelor competențe

1.3. Conducerea proceselor energetice

O problemă de optimizare este în mod obișnuit un model matematic în care noi urmărim să minimizăm o valoare numerică, care reprezintă ceva nedorit (cost, cheltuieli, pierderi, eroare etc) sau să maximizăm ceva care este dorit (profit, calitate, eficiență) [Song 02/2].

Dacă privim un proces sub aspectul conducerii optimale, principalele etape ale acestei acțiuni folosesc un algoritm general de tipul:

- Formularea problemei;
- Construcția modelului matematic;

Funcția obiectiv (FO):

$$\text{Min } F(X); \mathbf{X} = [X_1 \ X_2 \ \dots X_n]_t \quad (1.1.)$$

Restricții (R):

$$h_i(X) = 0, \quad i = 1, \dots, m_h \quad (1.2.)$$

$$g_i(X) \leq b_i, \quad i = 1, \dots, n_g \quad (1.3)$$

$$X_j \geq 0, \quad j = 1, \dots, n$$

- Determinarea și implementarea soluției optime.

Metodele de soluționare performante de astăzi îmbină tehnicile numerice tradiționale cu facilitățile oferite de tehnicile IA. Tehnicile IA sînt folosite în toate etapele unui asemenea algoritm, dar cu precădere pentru învingerea unor dificultăți legate de: modelarea multiobiectiv, tratarea restricțiilor, considerarea incertitudinilor (estimarea sarcinilor, costurilor etc). Deși aproape întodeauna se folosesc tehnici hibride de tipul Rețele neuronale artificiale (RNA) – Logica fuzzy (LF) – Sisteme expert (SE) – Algoritmi genetici (AG), există o recunoaștere cvasi unanimă a următoarelor preferințe:

- Algoritmi genetici $\Rightarrow$ Optimizare;
- Rețele neuronale $\Rightarrow$ Modelare-Interpolare;
- Logica fuzzy $\Rightarrow$ Control optimal;
- Sisteme expert $\Rightarrow$ Decizii.

Tehnicile hibride RNA-LF-SE-AG s-au dovedit extrem de performante în determinarea profilurilor consumatorilor, determinarea configurațiilor optime ale rețelelor de distribuție, analiza contingențelor rețelelor de înaltă tensiune, determinarea profilurilor optime ale tensiunilor etc.

1.4. Utilizarea modelării fuzzy

În ultimii ani cercetarea în domeniul exploatării și planificării sistemelor energetice se bucură de o atenție deosebită. Numeroase cercetări au în vedere abordări și modele noi, algoritmi performanți de calcul etc. Cel mai important obstacol în determinarea soluției optime se referă la caracterul neliniar și neconvex al modelelor de optimizare corespunzătoare.

Pe de altă parte, o mare parte a informației este incertă și chiar ambiguă. În planificarea distribuției, de exemplu, incertitudinea este determinată de erorile în măsurare, erorile în estimarea sarcinilor viitoare etc. Ca urmare, cea mai mare parte a datelor folosite în studiile de planificare pot prezenta grade de incertitudine destul de ridicate.

Din punct de vedere descriptiv, informațiile pot fi clasificate în următoarele categorii [Neimane 01]:

- deterministe (nivelele de tensiune, poziționarea stațiilor de transformare etc);
- probabiliste (fiabilitatea datelor privind componentele de rețea, indicatorii de calitate ai energiei consumate etc);
- fuzzy (informații sub formă lingvistică: Mare, Mediu, Mic etc). Deși informația fuzzy este cel mai adesea subiectivă, ea poate fi de mare ajutor pentru decident, Decision-Making (DM).

[Lang 00] prezintă, de exemplu, o metodă care permite determinarea fiabilității folosind Logica fuzzy și următoarele variabile lingvistice:

- Lungimi (Very Short, Short, Medium, Long, Very Long);
- Perioada de funcționare (Very Young, Young, Middle-Age, Old, Very Old);
- Riscul de întrerupere (Very Low, Low, Average, High, Very High).

Riscul de întrerupere este calculat în funcție de lungime și perioada de funcționare, folosind Logica fuzzy.

În general, modelele matematice de optimizare pot deveni improprii sau nerealistice atunci când încearcă să modeleze aspectele neingineresti, precum impactul asupra mediului, accesibilitatea la căile de comunicații etc. S-a constatat că din punct de vedere practic nu este necesar să introducem încă de la începutul planificării absolut toate detaliile. Este mult mai eficient ca acestea să fie introduse secvențial, într-o manieră iterativă pe parcursul căutării soluției.

Incetitudinea este, de regulă, cu atât mai mare cu cât perioada de planificare, de exemplu, este mai mare. Evident, incetitudinea este uneori inerentă exercițiului de planificare, astfel încât nu poate fi eliminată în totalitate. Se poate micșora riscul la care decidentul este expus datorită incetitudinii. Există două abordări de bază pentru a reduce incetitudinea în datele inițiale [Neimane 01]:

- îmbunătățirea măsurărilor existente, monitorizării și metodologiei de estimare;
- principiul perioadei minime pentru Decision-Making.

Este, de asemenea, evident că cu cât orizontul pentru care se face analiza este mai îndepărtat cu atât mai mare va fi și incetitudinea, Tabelul 1.1 [Willis 97].

Tabelul 1.1. Perioade de planificare tipice [Willis 97]

Nivel	Perioada de planificare [ani]	
	Termen scurt	Termen lung
Putere generată mare (> 150 MVA)	10	30
Putere generată mică (< 50 MVA)	7	20
Rețele de transport	8	25
Rețele de repartiție	6	20
Stații de distribuție	6	20
Rețele de fideri	6	20
Fideri principali	4	12
Fideri laterali	1	4

Pentru că în cadrul modelării fuzzy, definirea funcțiilor de apartenență este una din etapele cele mai importante, în lucrare se acordă o atenție deosebită acestui aspect cu multiple posibilități de aplicație și implicație. Astfel, în Fig.1.3, 1.4 și 1.5 se prezintă, ca exemplu, pașii de definire a unor funcții de apartenență trapezoidale pentru cazul a trei mulțimi bidimensionale. În capitolele următoare este expusă pe larg și în mod sistematic o tehnică adecvată de grupare spațială (clustering), care ușurează definirea funcțiilor de apartenență, precum și numeroase aplicații în determinarea pierderilor de putere în rețelele de distribuție, determinarea profilurilor optime de reglaj în rețelele de transport etc, pe baza Logicii fuzzy.




Fig. 1.3. Exemple de elemente negrupate




Fig. 1.4. Exemple de grupare a elementelor




Fig. 1.5. Exemple de definirea a unor funcții de apartenență

1.5. Perspective privind IA

Pentru a decela viitorul IA este util să facem o privire mai largă asupra actualelor tendințe chiar asupra muncii fizice și muncii intelectuale. De la începuturile ei, civilizația a fost structurată, în cea mai mare parte, în jurul conceptului de muncă. Între timp munca fizică a început să fie eliminată din procesul de producție. Tot mai multe mașini sofisticate înlocuiesc oamenii, trimițându-i către servicii și uneori către șomaj.

În privința muncii intelectuale ne putem aștepta la evoluții oarecum similare. Din 1956, când s-a utilizat pentru prima dată termenul de IA, s-au schimbat multe. Există numeroase opinii precum că în acest secol, poate nu peste mult timp, forța tehnologică a IA va fi capabilă să depășească mintea umană medie [Rifkin 95], [Rifkin 02]. Există deja mașini care recunosc vocea, care poartă conversații semnificative și chiar solicită informații suplimentare pentru anumite decizii, pot face recomandări și pot răspunde la întrebări. Numeroși oameni de știință așteaptă ziua când mașinile vor fi suficient de sofisticate pentru a putea crea, pentru a avea propria conștiință, fără intervenții consultative. Mai mult decât atât, există o preocupare pentru umanizarea acestor mașini, ca acestea să creeze imagini naturale (ale feței), care să converseze cu utilizatorul. Către jumătatea secolului se așteaptă imagini holografice în mărime naturală ale ființelor umane generate de calculator, capabile să interacționeze cu oamenii reali, în timp și spațiu real.

Sectorul energiei electrice a fost întotdeauna unul din primii beneficiari ai tehnicilor de vîrf, dar și unul din promotorii de bază ai acestor tehnici. Acesta a reprezentat un domeniu privilegiat și pentru aplicațiile Inteligenței artificiale. În principiu, este vorba de o mare diversitate de aplicații referitoare la modelarea și conducerea proceselor energetice care folosesc Rețele neuronale artificiale, Sisteme expert, Logica fuzzy și Algoritmi genetici.



Bibliografie

- [Alexandrescu 01] Alexandrescu, V., Cârțină, Gh., Grigoraș, Gh., Using Fuzzy Load Models in Distribution Network Monitoring and Control, Proc. of the Conference Modeling and Optimization in the Machines Building Field, 2001, Bacău, Vol. 1, pp. 236 – 241.
- [Carvalho 00] Carvalho, P., Ferreira, L., Lobo, F., Barrucho, L., Distribution Network Expansion Planning under Uncertainty: A Hedging Algorithm in an Evolutionary Approach, IEEE Trans. on Power Systems, 2000, Vol. 15, No. 1, pp. 412 - 416.
- [Cârțină 94] Cârțină, Gh., Georgescu, Gh., Gavrilăș, M., Bonciu, Cl., Rețele neuronale artificiale și sisteme expert în energetică, Ed. "Gh. Asachi", Iași, 1994.
- [Cârțină 98] Cârțină, Gh., Bonciu, Cl., Mușat, M., Zisman, Z., Losses Minimization in Power Systems Using Artificial Neural Networks, Proc. of Mediterranean Electrotechnical Conference, MELECON'98, 1998, Tel-Aviv, Israel, Vol. 2, pp. 1103 -1106.
- [Cârțină 99] Cârțină, Gh., Alexandrescu, V., Bonciu, Cl., Bîrlădeanu, E., Coordination of Voltage/Reactive Power Control Using Fuzzy Dynamic Programming, Proc. of ELECTRIMACS'99, 1999, Lisbona, Portugalia, Vol. 1, pp. 127 - 131.
- [Cârțină 00] Cârțină, Gh., Bonciu, Cl., Bîrlădeanu, E., Moshe, M., Optimization of the Decisions for the Renewal/Reinforcements on Distribution Networks, Proc. of Mediterranean Electrotechnical Conference, MELECON'00, 2000, Nicosia, Cipru, Vol. 3, pp. 911 - 914.
- [Cârțină 01/1] Cârțină, Gh., Grigoraș, Gh., Using Fuzzy Reliability Indices in Planning of the Distribution Networks, Proc. of the 6th Intern. Symposium on Automatic Control and Computer Science, SACCS'01, 2001, Iași, Lucrarea s28, CD-ROM.
- [Cârțină 01/2] Cârțină, Gh., Alexandrescu, V., Bîrlădeanu, E., Grigoraș, Gh., Moshe, M., Power Distribution System Reliability Planning Using Fuzzy Logic, Proc. of the 24th International Conference on Fundamentals of Electrotechnics and Circuit Theory, IC-SPETO'01, 2001, Gliwice-Ustron, Polonia, Vol. 2, pp. 353 – 356.
- [Cârțină 01/3] Cârțină, Gh., Grigoraș, Gh., Inteligența artificială. Optimizări în energetică, Casa de Editură VENUS, Iași, 2001.
- [Cârțină 02/1] Cârțină, Gh., Grigoraș, Gh., Tehnici moderne de optimizare. Aplicații în energetică, Casa de Editură VENUS, Iași, 2002.

CAPITOLUL 2

PRINCIPIILE INTELIGENȚEI ARTIFICIALE

Conceptul de **Inteligență artificială (IA)** a fost elaborat în jurul anilor '50. De atunci s-a lărgit continui și astăzi acoperă o întreagă gamă de tehnologii, cuprinzând în primul rând **Sistemele expert (SE)**, **Rețelele neuronale artificiale (RNA)**, **Logica fuzzy (LF)** și **Algoritmii genetici (AG)**.

IA a fost întotdeauna un domeniu mai mult sau mai puțin controversat, perioadele de dominare a unor atitudini alternând în decursul vremii, în funcție de evoluția diferitelor succese sau insuccese de moment ale acestor tehnologii. Este însă tot mai evident că rezolvarea eficientă a unui număr de probleme legate, de exemplu, de exploatarea de zi cu zi a sistemului energetic, trece prin elaborarea unor soluții bazate pe o formă sau alta de IA. În aceste privințe este mai productiv de a evita controversele și a accepta orice propunere care a făcut dovada viabilității sale. Într-un sector "pragmatic și destul de conservator", ca acela al energiei electrice, acest punct de vedere prevalează și cea mai mare parte a companiilor/societăților de electricitate utilizează IA de o manieră sau alta, în domeniul așa de complex al conducerii on-line a instalațiilor energetice.

În centrele de conducere, diferite sisteme informatice furnizează operatorilor un ajutor substanțial înainte și după evenimente. Tehnologia clasică nu permite în general furnizarea unor asistențe dorite în momente oportune. Lăsând la o parte numeroasele date brute furnizate de SCADA, ajutorul în timp real este limitat. Aceasta cu atât mai mult cu cât operatorul are obiceiul de a gândi în anumite circumstanțe date. Într-un asemenea context IA poate constitui o alternativă oportună.

Pe măsură ce un sistem cu Inteligență artificială are de rezolvat sarcini mai complexe, crește din ce în ce mai mult cunoașterea ce trebuie reprezentată în el (fapte, reguli și euristici ale domeniului, concepte generale și teorii). În general un sistem funcționează bine, în concordanță cu scopul fixat prin cunoașterea furnizată, dar orice mișcare în afara competenței sale face ca performanțele sale să scadă rapid. Acest fenomen este numit și **fragilitatea cunoașterii**. Pentru a evita apariția lui în sistem, trebuie încărcată toată cunoașterea reclamată de scopul urmărit. Dar încărcarea cunoașterii necesare în fiecare sistem nou este un proces foarte complex,

consumator de timp, predispus la eroare și reclamînd o expertiză specială. Această sarcină ar putea fi simplificată utilizînd **metode de autoinstruire a mașinilor**. Aceste metode ar putea permite unui sistem să dezvolte reguli de decizie proprii pornind de la exemplele furnizate de către deciziile experților și/sau utilizînd analiza automată a faptelor din baza de date a sistemului.

Tehnologiile IA (SE, RNA, LF, AG) au un puternic caracter interdisciplinar, reflectat în metodele și instrumentele folosite pentru descrierea formală: tehnica prelucrării semnalelor, statistica matematică, teoria optimizării, termodinamica, ingineria cunoștințelor, teoria învățării etc.

Acest capitol prezintă o introducere în principiile care guvernează Sistemele expert, Rețelele neuronale artificiale, Logica fuzzy și Algoritmii genetici. Sistemele expert sînt concepute și proiectate pentru simularea procesării cunoștințelor de către sistemele biologice. Rețelele neuronale artificiale încearcă să simuleze mecanismele de procesare a informației la sistemele biologice. Logica fuzzy permite reprezentarea incertitudinii și a cunoștințelor imprecise, folosite de către experți în limbajul natural, iar Algoritmii genetici sînt destinați, în special, unor aplicații de optimizare complexă.

Este util de subliniat că, deși posibilitățile de moment ale acestor tehnici sînt încă departe de performanțele sistemelor biologice respective, modul de abordare a problemelor, cît și rezultatele obținute sînt destul de promițătoare.

2.1. Rețele neuronale artificiale (RNA)

2.1.1. Caracteristicile și limitele RNA

Asistăm astăzi la o extraordinară explozie în apariția diferitelor aplicații ale Rețelelor neuronale artificiale (RNA). Un număr din ce în ce mai mare de cercetători sînt actualmente interesați de calitățile de învățare și de robusteță ale acestora. Tehnicile bazate pe RNA par să revoluționeze problemele tratate pînă în prezent prin statistica clasică. Aplicațiile respective merg de la simple prognoze, la conducerea proceselor, de la recunoașterea formelor, la diagnoza unor defecte în stare incipientă etc. RNA sînt elemente care împreună cu celelalte tehnici (Sistemele expert, Logica fuzzy, Algoritmii genetici) vor da noi valențe, dintre care unele, poate, neabătute astăzi, aplicațiilor inteligenței artificiale.

Cu toate progresele și performanțele realizate în domeniul calculatoarelor electronice, a devenit din ce în ce mai clar că există domenii și probleme unde acestea sînt inefficiente. Astfel, calculatorul electronic modern, cu unul sau mai multe microprocesoare, excepțional de rapid, este capabil de a realiza un număr impresionant de calcule pe secundă. Aceasta îl face apt pentru operații simple, repetitive, care vizează, mai ales, calcule asupra numerelor. Calculatoarele

tradiționale sînt instrumente extrem de adecvate în rezolvarea unui spectru larg de probleme matematice, științifice, ingineresti etc.

Același calculator, performant în prelucrarea serială a unui volum mare de operații aritmetice, rămîne slab și neputincios la "**operații elementare**" pentru creierul uman, cum ar fi: modelarea pe bază de loturi de exemplare, recunoașterea formelor, recunoașterea vorbirii, rezolvarea altor probleme din aceste categorii sau înrudite. Precizăm că, în acest caz, prin recunoașterea formelor, înțelegem interpretarea imaginilor, în sensul extragerii informațiilor despre prezența și/sau absența caracteristicilor unui obiect de interes. Aceste operații, simple pentru creierul uman, sînt în realitate procese complexe, cu foarte multe intrări paralele diferite și conflictuale. Creierul uman, deși mai lent, este excelent în realizarea performantă a unor asemenea sarcini. El este structurat astfel încît să facă realizarea unor procese complexe, cît mai ușor posibilă, ceea ce înseamnă că există și alte lucruri pe care nu le poate face la fel de bine.

Funcționalitatea modularizată (paralelă) a creierului uman, cunoscută ca procesare distribuită, are avantajul de a-l face tolerant la erori, ceea ce constituie o trăsătură vitală a funcționării sale, deoarece în fiecare zi un număr de neuroni moare, ca urmare a unui proces natural. Deși pierderile cumulative sînt din ce în ce mai mari, creierul uman continuă să funcționeze ca și cum nimic nu s-ar fi întîmplat.

Dintre caracteristicile cele mai atractive ale RNA menționăm: procesarea paralelă, învățarea prin exemple, comportarea bună în regim de date de intrare parțial perturbate și faptul că, problema prezentată în perioada de antrenare nu trebuie formalizată prin reguli clare. Această ultimă caracteristică face posibilă modelarea unor procese complexe, ale căror legi de funcționare sînt fie prea complicate, fie încă sînt echivoce, din punct de vedere analitic.

Toate cele de mai sus sînt motive întemeiate pentru o abordare a calcului neuronal cu scopul înțelegerii principiilor ce stau la baza funcționării creierului uman și aplicarea acestor principii, în măsura posibilului, în sistemele de inteligență artificială.

Ideea de a căuta în structura sistemului nervos o sursă de inspirație pentru concepția sistemelor de tratare a informației nu este nouă. În anul 1943, în încercarea de a explica modul în care creierul uman realizează funcțiile booleene, W. McCulloch și S. Pitts au propus **modelarea celulei nervoase (neuronul)** printr-un automat cu prag, denumit **neuron formal**. Cercetările în domeniul RNA cunosc o efervescență deosebită, mai cu seamă după apariția perceptronului [Roseblatt 58]. În 1969, M. Minsky și S. Papert publică însă un studiu, în care evidențiază limitele teoretice ale perceptronului și, mai ales, imposibilitatea modelării cu ajutorul acestuia a funcțiilor logice XOR (SAU EXCLUSIV) [Minsky 69].

Noi modele ale procesului de învățare, propuse de Rumelhart și McClelland (1986), Hopfield (1982), Kohonen (1984), Grossberg (1980) și alții, au inițiat un mare val de cercetări în domeniul calculului neuronal.

Toate modelele de RNA se bazează pe interconectarea unor elemente simple de calcul într-o rețea densă de conexiuni. Fiecare unitate de procesare este capabilă să

execute doar calcule simple, dar rețeaua, ca întreg, poate avea calități remarcabile în recunoașterea formelor, rezolvarea unor probleme pentru care nu posedăm un algoritm, învățarea din exemple. Învățând din aceste exemple (faza de instruire), aceste rețele sînt capabile să trateze cazuri similare (faza de lucru/generalizare). RNA mai sînt cunoscute și sub multe alte denumiri, cum ar fi: **modele conexiuniste, modele de prelucrare paralelă distribuită, sisteme neurodinamice.**

Paralelismul înalt și capacitatea de învățare (antrenare/instruire) reprezintă caracteristicile fundamentale ale RNA. Soluționarea problemelor reale cu metodele RNA se bazează pe prelucrarea unor volume mari de date, iar scopul este obținerea unor instrumente de lucru care să opereze on-line.

Interesul inițial pentru RNA s-a datorat, în mare măsură, și afirmației că acestea pot explicat mecanismele de bază și dinamica creierului uman. RNA actuale sînt foarte departe de structura neuronală biologică și de simularea proceselor cognitive. Diferențele se referă atît la arhitectură, cît și la proprietăți. Dintre diferențe menționăm pe cele mai importante:


- RNA nu copiază structurile neuronale biologice, ci reprezintă modele mult simplificate ale acestora;
- RNA sînt realizate pe baza cîtorva tipuri de neuroni artificiali, în timp ce neuronii biologici cunosc o mare varietate;
- Există o diferență semnificativă între numărul neuronilor artificiali dintr-o RNA și numărul neuronilor biologici;
- RNA au de obicei topologii de interconectare regulate, în timp ce în creierul uman multe din conexiuni par aleatorii sau statistice;
- Majoritatea RNA sînt sincrone, în timp ce sistemele biologice realizează modificările asincrone etc.

2.1.2. Modele și structuri de RNA

Elementul de bază al unei RNA este **neuronul**, unitate de procesare foarte simplă. Primul model formal al neuronului, privit ca element de procesare a informației, a fost propus de W. McCulloch și S. Pitts, în anul 1943. Acesta, numit **neuron formal**, este un element de procesare a informației care modelează de o manieră simplificată, neuronul real.

Funcția de bază a unui neuron artificial (ca și a unuia biologic) este, ca, folosind o anumită schemă, să adune intrările într-un anumit mod și să producă o ieșire, dacă suma respectivă depășește un anumit prag.

Dacă se notează cu net_j , mărimea ce descrie efectul intrărilor asupra neuronului, și cu f_j , funcția de transfer, numită aici **funcție de activare**, ce se aplică acestei mărimi, funcționarea unui neuron, Fig. 2.1, văzut ca element de procesare în intervale discrete de timp, poate fi descrisă de relațiile:



$$net_j = \sum_{i=1}^n W_{ij} X_i(t) - \theta_j \quad (2.1)$$

$$Y_j = f_j(net_j) \quad (2.2)$$

Fig. 2.1. Modelul neuronului formal

Funcțiile de activare folosite frecvent în RNA sînt: funcția treaptă (Fig. 2.2), rampă (Fig. 2.3) și sigmoid (Fig. 2.4). Se observă că funcția sigmoidală reprezintă forme netezite ale funcției rampă, este continuă, derivabilă și monoton crescătoare, proprietăți foarte convenabile pentru aplicații.




Fig. 2.2. Funcția treaptă




Fig. 2.3. Funcția rampă




Fig. 2.4. Funcția sigmoid

Indeplinirea unor funcții care să facă posibilă abordarea unor probleme complexe, de interes practic, este posibilă numai dacă neuronii sînt asociați într-un sistem numit **Rețea neuronală artificială (RNA)**. RNA sînt formate din neuroni (elemente de procesare), aranjați pe **straturi** și legați prin **conexiuni sinaptice**, caracterizate de anumite **ponderi**. Neuronii din primul strat nu au rol de procesare, ci numai de preluare a mărimilor de intrare în rețea. RNA dobîndesc capacitatea lor de procesare asociind acești neuroni simpli din rețea, printr-o matrice de ponderi **W**. Cu cît valoarea absolută a ponderii **W_{ij}** este mai mare, cu atît influența neuronului **i** asupra neuronului **j** este mai mare.

În ultimii ani a fost dezvoltată o mare varietate de modele de RNA pentru diferite scopuri. Acestea diferă prin structură, principii de funcționare, implementare, dar au și o serie de proprietăți comune, dintre care cea mai de seamă

este procesarea distribuită paralelă. Există mai multe posibilități de clasificare a rețelelor neuronale. Dintre aceste, în continuare, vom prezenta două criterii:

- După sensul de transfer al informației se disting: **rețele statice și dinamice**;
- După modul de învățare, există **rețele cu învățare supravegheată și nesupravegheată**.

În cazul rețelelor statice, datele primite din exterior tranzitează rețeaua întotdeauna în sens unic, de la intrare către ieșire, de unde și denumirea de **rețele feedforward**. Altfel spus, grafurile de conexiune ale acestor rețele nu conțin bucle. Aceste rețele sînt folosite cu precădere pentru probleme de clasificare, modelarea proceselor statice etc. Din această categorie fac parte rețelele de tipul **Perceptronului multistrat**. Rețelele dinamice comportă bucle de reacție, ceea ce determină o evoluție mai complexă în timp. Din acestea fac parte **rețelele feedback**, **rețelele plasă** etc.

Referitor la cel de-al doilea criteriu de clasificare, învățarea supervizată se desfășoară pe baza unor exemplare (**patterns**), care comportă perechi univoce intrare/ieșire. În cazul învățării nesupravegheate are loc un proces de autoorganizare a rețelei, ne mai fiind necesară precizarea unor corelații intrare/ieșire. Dintre rețelele cu învățare nesupravegheată cităm **rețelele Kohonen** (care sînt totodată și rețele dinamice) și se folosesc în special pentru probleme de clasificare, dar nu numai.

Deci într-o RNA, se pot distinge cel puțin două etape de funcționare: **etapa de învățare (antrenare)** și **etapa de recunoaștere (generalizare)**. Mai există o a treia etapă, de testare. În etapa de antrenare, parametrii rețelei (ponderile conexiunilor sinaptice W_{ij}) sînt ajustați pe măsura prezentării perechilor de vectori intrare/ieșire. Etapa de recunoaștere constă în exploatarea rețelei, adică pentru date de intrare ce nu figurau în lotul de antrenare, RNA oferă un răspuns la ieșire. Cele două etape de funcționare se întrepătrund adesea.

Prima teorie asupra învățării în sistemele neuronale biologice a fost dezvoltată de Hebb în 1949 [Hebb 49]. În principiul de învățare, Hebb introduce implicit noțiunea de eficiență sinaptică, care, în mod obișnuit, se modelează printr-un număr real, numit ponderea conexiunii. Cu cît această pondere este mai mare în valoare absolută, cu atît efectul activării neuronului receptor va fi mai mare.

Una din metodele de învățare folosită frecvent, **LMS (Least Mean Square)**, presupune determinarea unei soluții prin ajustări succesive ale ponderilor W , pe măsura prezentării perechilor de vectori intrare/ieșire. Metoda de învățare LMS are la bază folosirea gradientului funcției erorii pătratice instantanee, ca aproximare a gradientului funcției erorii pătratice medii. De fapt, deplasarea iterativă, în procesul de optimizare, se face după direcția antigradienților respectivi.

2.1.3. Perceptronul multistrat (MLP)

2.1.3.1. Structura și funcționarea MLP

Limitele perceptronului (de exemplu, imposibilitatea modelării funcției logice SAU EXCLUSIV) pot fi depășite prin utilizarea mai multor perceptroni, dispuși într-o rețea cu organizare stratificată, ca în Fig. 2.5. Datorită acestui tip de organizare, asemenea rețele neuronale poartă numele de **perceptron multistrat (MLP, Multi Layer Perceptron)**. Acesta reprezintă cel mai utilizat tip de RNA. Actualul nivel de performanță este datorat și modelului de învățare cu retropropagarea erorii (**Backerrorpropagation**) [Rumelhart 86].

Celulele elementare ale MLP se numesc **neuroni** și se deosebesc de perceptronul definit de Rosenblatt [Rosenblatt 86] prin utilizarea unor funcții de activare de tip **sigmoid**, Fig. 2.6, în locul funcției treaptă.

Intr-o asemenea rețea neuronii sînt organizați în straturi: un **strat de intrare**, un **strat de ieșire** și unul sau mai multe **straturi ascunse (intermediare)**. De regulă, fiecare neuron al unui strat este conectat cu toți neuronii din stratul imediat superior ("**fully – connected networks**") și nu se admit legături între neuronii ce nu aparțin unor straturi consecutive. Există, însă, situații în care se folosesc asemenea legături, numite "**short-cut connections**", cu rolul de a întări influența unei anumite intrări asupra ieșirii RNA.

Numai neuronii din straturile ascunse și, eventual, cei din stratul de ieșire realizează o procesare a informației. Stratul de intrare servește doar la distribuirea intrărilor, pe care rețeaua le preia din exterior.




Fig. 2.5. Schema MLP




Fig. 2.6. Funcția sigmoid

În general, RNA multistrat sînt modele neliniare ce realizează "**aproximarea universală**", adică pot aproxima orice relație intrare-ieșire continuă, pe baza

teoremelor lui Kolmogorov, Cybenko ș.a. Teorema lui Kolmogorov dă și structura unui asemenea MLP cu trei straturi și funcții de activare sigmoïdale $[M; 2M+1; N]$, M și N reprezentând numărul de elemente din primul strat (care nu afectează prelucrări), respectiv, din ultimul strat. Este foarte important faptul că teoremele de reprezentare neuronală ale lui Kolmogorov ș.a. sînt date doar ca teoreme de existență. Adică garantează faptul că există o structură neuronală "feedforward", care implementează funcția $f(X)$, dar nu precizează cum se poate construi modelul neuronal. În ceea ce privește numărul neuronilor din celelalte straturi (intrare, ieșire), acesta depinde de problema specifică analizată, neexistînd o procedură generală de dimensionare a unei astfel de rețele.

Folosirea MLP conduce la arhitecturi mai robuste, cu performanțe superioare, capabile să recunoască funcții mai complexe. Antrenarea MLP este considerată o problemă de optimizare, iar cei mai folosiți algoritmi sînt cei de tipul **retropropagare (Backpropagation sau Generalized Delta Rule)**. Algoritmul **standard (Vanilla BackPropagation)** a fost elaborat independent de mai mulți autori, prima variantă datînd din 1973.

Algoritmul de retropropagare este o metodă de tip LMS, care urmărește determinarea acelor ponderi W care minimizează suma pătratelor diferențelor dintre ieșirile dorite și cele curențe, cînd vectorul de intrare parcurge baza de învățare.

2.1.3.2. Algoritmul de învățare al MLP

Deși, în principiu, pentru găsirea minimului funcției eroare pătratică $E(W)$ se pot folosi oricare din metodele de optimizare (gradient conjugat, Newton, cvasi Newton etc), dintre formulările cele mai recomandate menționăm pe cele bazate pe coborîrea după direcția antigradientului funcției $E(W)$ [Rumelhart 86], după o tehnică iterativă de tipul:

$$W(t+1) = W(t) + \eta(t) \cdot \nabla_W E(W(t)) \quad (2.3)$$

unde $\eta(t)$ este rata de învățare.

Dacă se fac următoarele notații:

t_j – ieșirea dorită de la neuronul j al MLP;

o_j – ieșirea curentă la neuronul j al MLP;

W_{ij} – ponderea legăturii de la neuronul i la neuronul j ,

funcția eroare pătratică E , denumită și funcție de energie, are expresia:

$$E = E(W) = \frac{1}{2} \sum_{j=1}^n (t_j - o_j)^2 \quad (2.4)$$

unde n este numărul neuronilor din stratul de ieșire.

Ieșirea neuronului j este determinată de funcția f_j , activată de suma ponderată a intrărilor. Obșnuit se folosește ca funcție de activare, o funcție sigmoid sau oricare altă funcție monotonă, continuu diferențiabilă:

$$o_j = f_j(net_j); \quad net_j = \sum_{i=1}^m W_{ij} o_i \quad (2.5)$$

unde m este numărul de neuroni din stratul imediat inferior stratului de ieșire.

Folosind regula de derivare pentru funcțiile compuse, aplicată funcției eroare, se poate scrie succesiv:

$$\frac{\partial E}{\partial W_{ij}} = \frac{\partial E}{\partial net_j} \cdot \frac{\partial net_j}{\partial W_{ij}} \quad (2.6)$$

$$\frac{\partial net_j}{\partial W_{ij}} = \frac{\partial}{\partial W_{ij}} \sum_{k=1}^m W_{kj} \cdot o_k = o_i \quad (2.7)$$

Variația funcției eroare E , ca urmare a modificării intrării neuronului j , net_j , notîndu-se cu:

$$-\frac{\partial E}{\partial net_j} = \delta_j \quad (2.8)$$

se obține pentru una din componentele antigradientului:

$$-\frac{\partial E}{\partial W_{ij}} = \delta_j o_i \quad (2.9)$$

Prin urmare, pentru descreșterea valorii funcției eroare, E , este necesară modificarea ponderilor W_{ij} , proporțional cu $\delta_j o_i$, adică:

$$\Delta W_{ij} = \eta \delta_j o_i \quad (2.10)$$

În acest scop este nevoie să se cunoască termenul eroare, δ_j , pentru fiecare neuron. Folosind relațiile (2.8), (2.4), (2.5) se poate scrie:

$$\delta_j = - \frac{\partial E}{\partial net_j} = - \frac{\partial E}{\partial o_j} \cdot \frac{\partial o_j}{\partial net_j} \quad (2.11)$$

$$\frac{\partial E}{\partial o_j} = - (t_j - o_j) \quad (2.12)$$

$$\frac{\partial o_j}{\partial net_j} = f'(net_j). \quad (2.13)$$

iar în final, rezultă termenul eroare:

$$\delta_j = f'(net_j)(t_j - o_j) \quad (2.14)$$

Acest calcul este valabil pentru neuronii de ieșire, deoarece ieșirile dorite, (t_j), și cele curente, (o_j), sînt accesibile. Nu același lucru este valabil și pentru neuronii din stratul ascuns, întrucît ieșirile dorite, pentru aceștia sînt necunoscute. De aceea, dacă neuronul j nu este de ieșire, calculăm mai întîi:

$$\frac{\partial E}{\partial o_j} = \sum_k \frac{\partial E}{\partial net_k} \frac{\partial net_k}{\partial o_j} = \sum_k \frac{\partial E}{\partial net_k} \frac{\partial}{\partial o_j} \sum_i W_{ik} o_i = - \sum_k \delta_k W_{jk} \quad (2.15)$$

Înlocuind relațiile (2.15) și (2.13) în (2.11), se găsește expresia termenului eroare pentru neuronii din stratul ascuns:

$$\delta_j = f'_j(net_j) \sum_k \delta_k W_{jk} \quad (2.16)$$

unde însumarea se face pentru toți neuronii k din stratul imediat superior celui în care se află neuronul j .

Se constată, astfel, dependența erorii δ_j , într-un strat, de erorile, δ_k , ale tuturor neuronilor din stratul superior. Prin urmare, este necesar să se calculeze, mai întîi, erorile asociate neuronilor din stratul de ieșire, rel. (2.14), după care se coboară prin rețea, către straturile inferioare, pentru modificarea ponderilor conexiunilor sinaptice, de unde provine și numele metodei de retropropagare.

Merită menționate motivațiile folosirii funcției sigmoid ca funcție de activare a neuronilor MLP. Această funcție se aseamănă destul de mult cu funcția treaptă și are o comportare similară acesteia. Funcția sigmoid logistic este definită prin relația:

$$f(net) = \frac{1}{1 + e^{-\lambda_{net}}} \quad (2.17)$$

și ia valori în intervalul (0,1).

- **P1.** Inițializarea aleatoare a ponderilor conexiunilor sinaptice;
- **P2.** Alegerea aleatoare a următoarei perechi de vectori intrare/ieșire;
- **P3.** Propagarea înainte; pentru vectorul de intrare se determină ieșirile o_j ;
- **P4.** Se compară ieșirile curente cu cele dorite, pentru a determina o măsură a erorii. Dacă sînt satisfăcute condițiile de oprire, procesul de învățare se sistează;
- **P5.** Determinarea și efectuarea corecțiilor ponderilor, astfel încît să se reducă eroarea. Se pleacă de la stratul de ieșire și se merge înapoi, către stratul de intrare:

$$W_{ij}(t+1) = W_{ij}(t) + \eta(t) \cdot \delta_j(t) \cdot o_i(t) \quad (2.18)$$

unde: $W_{ij}(t)$ – ponderea conexiunii sinaptice dintre neuronul i și neuronul j , în iterația (t) ;

$\eta(t)$ – rata de învățare, în iterația (t) ;

$\delta_j(t)$ – termenul eroare pentru neuronul j , în iterația (t) .

Pentru neuronii din stratul de ieșire se consideră:

$$\delta_j = \lambda o_j (1 - o_j) (t_j - o_j) \quad (2.19)$$

iar pentru neuronii din stratul ascuns:

$$\delta_j = \lambda o_j (1 - o_j) \sum_k \delta_k W_{jk} \quad (2.20)$$

unde însumarea în raport cu k se face pentru neuronii din stratul imediat superior celui în care se află neuronul j .

- **P6.** Se repetă etapele precedente (**P2 – P5**), cu celelalte perechi de vectori, alese aleator din mulțimea de antrenare, pînă cînd sînt satisfăcute condițiile de oprire, adică eroarea se încadrează în limita impusă.

Fig. 2.7. Algoritm de învățare al MLP

În relația (2.17) de mai sus, λ este o constantă pozitivă care controlează dispersia funcției: valori mari ale lui λ conduc la saturarea rapidă a funcției, iar pentru λ tinzând la infinit, $f(\text{net})$ tinde la funcția Heaviside. Constanta λ acționează ca un control automat al câștigului, deoarece pentru semnale mici de intrare, panta devine treaptă, astfel încât funcția se modifică rapid, producând un câștig mare. Pentru semnalele mari de intrare, panta și câștigul relativ devin mult mai mici. Aceasta înseamnă că rețeaua respectivă acceptă intrări mari și rămâne totdeauna sensibilă la intrările mici, lucru foarte important din punct de vedere practic.

Un alt motiv major pentru folosirea funcției sigmoid este că aceasta are o derivare simplă, ceea ce face implementarea metodei de retropropagare mult mai comodă. Dacă se consideră cunoscută ieșirea neuronului j , o_j :

$$o_j = f_j(\text{net}_j) = \frac{1}{1 + e^{-\lambda \text{net}_j}} \quad (2.21)$$

derivata corespunzătoare este:

$$f'_j(\text{net}_j) = \frac{\lambda \cdot e^{-\lambda \text{net}_j}}{(1 + e^{-\lambda \text{net}_j})^2} = \lambda f_j(\text{net}_j)(1 - f_j(\text{net}_j)) \quad (2.22)$$

de unde:

$$f'_j(\text{net}_j) = \lambda o_j(1 - o_j) \quad (2.23)$$

Deci determinarea derivatei se face prin calculul unei simple expresii, în funcție de semnalul de ieșire. În baza celor de mai sus se deduce că algoritmul de antrenare al MLP comportă etapele principale cuprinse în Fig.2.7.

Algoritmul de învățare se bazează pe tehnica de căutare a unui minim al suprafeței de eroare, prin folosirea direcției antigradientului (instantaneu). Funcția ce se minimizează nefiind convexă, nu întotdeauna se ajunge, prin antrenare, la un minim global, ci adeseori la unul local.

Menționăm faptul că învățarea după gradient este una dintre cele mai simple, dar și una dintre cele mai lente metode de optimizare a învățării RNA. Se poate mări substanțial viteza de convergență a algoritmului de învățare, ajustând valoarea ratei de învățare, η , la valoarea sa optimală, printr-o metodă de interpolare polinomială [Comon 92]. O altă manieră, mai performantă, dar mai costisitoare, este utilizarea algoritmilor de tip cvasi Newton [Watrou 88], [Comon 92] etc.

2.1.4. Aspecte practice privind utilizarea RNA

2.1.4.1. Selectarea seturilor de învățare

În legătură cu folosirea RNA de tip MLP pentru rezolvarea unor probleme concrete, se impun câteva observații de ordin practic.

O primă observație se referă la alegerea bazelor de învățare și generalizare. În acest sens, criteriul de minimizare folosit în algoritmul de învățare **backpropagation** prezintă un inconvenient major. După cum s-a menționat, acest algoritm urmărește minimizarea funcției eroare, dar, din nefericire, această minimizare se efectuează folosind baza de învățare, în timp ce performanțele reale ale RNA trebuie apreciate pentru baza de generalizare.

De aceea, o învățare performantă implică existența unei legături între baza de învățare și baza de generalizare. Astfel, se presupune că cele două baze sînt realizări aleatorii conforme, cu aceeași densitate de probabilitate.

Este, de asemenea, util să menționăm faptul că, în învățarea supravegheată, în general, și algoritmul **backpropagation**, în particular, există riscul de „supraînvățare”, de o manieră particulară mascată [Comon 92]. Dacă baza de învățare este mică în raport cu numărul parametrilor liberi, W_{ij} , eroarea poate atinge în cursul învățării valori mici, chiar nule. Aceasta nu reprezintă însă o garanție a micșorării probabilității de eroare pentru baza de generalizare. Din contră, supraînvățarea are drept consecință, mărirea erorilor. Riscul supraînvățării este cu atât mai mare, cu cît dimensiunile rețelei cresc, în raport cu baza de învățare. În acest sens, se poate demonstra că ieșirile MLP tind către probabilitățile bayesienne, cînd mărirea bazei de învățare tinde către infinit [Comon 92].

2.1.4.2. Scalarea variabilelor

Deoarece variabilele de intrare și de ieșire ale RNA au, în general, domenii de definiție oarecare, folosirea datelor originale în RNA va pune probleme de convergență. Aceasta se datorește faptului că, în timp ce numeroase aplicații se caracterizează prin valori reale oarecare ale intrărilor, majoritatea RNA folosesc funcții de activare care restrîng domeniul de variație al mărimilor de ieșire, de exemplu, la $(-1, +1)$. Pentru a evita acest impas este necesară scalarea domeniului variabilelor respective. Se acceptă, în general, două scheme de scalare. Pentru o mai ușoară definire a acestor scheme, să presupunem că datele de intrare X_i^k conțin 5 componente, $i = 1, \dots, 5$, și 7 exemplare, $k = 1, \dots, 7$. Prima folosește ca referință valoarea maximă a variabilelor respective:

$$X_{ibaza} = \max_k (X_i^k), \quad k = 1, \dots, 7; \quad i = 1, \dots, 5 \quad (2.24)$$

$$o_{baza} = \max_k(o^k) \quad k = 1, \dots, 7 \quad (2.25)$$

unde:

k - numărul exemplarelor din lotul de antrenare;

i - numărul componentelor fiecărui exemplar.

Valorile scalate ale parametrilor de intrare și de ieșire se obțin, prin raportarea la mărimile de bază corespunzătoare:

$$X_{i\text{scal}}^k = \frac{X_i^k}{X_{i\text{baza}}^k} \quad k = 1, \dots, 7; \quad i = 1, \dots, 5 \quad (2.26)$$

$$o_{\text{scal}}^k = \frac{o^k}{o_{baza}^k} \quad (2.27)$$

În acest caz, mărimile scalate au valori între 0 și 1. A doua schemă de scalare folosește relațiile:

$$X_{i\text{scal}}^k = \frac{X_i^k - X_{i\text{med}}}{S_i} \quad k = 1, \dots, 7; \quad i = 1, \dots, 5 \quad (2.28)$$

$$o_{\text{scal}}^k = \frac{o^k - o_{\text{med}}}{S_o} \quad k = 1, \dots, 7 \quad (2.29)$$

unde:

S_i - estimarea abaterii standard a variabilelor respective;

$X_{i\text{med}}$ - estimarea valorii medii a aceluiași variabile.

În multe cazuri, cea de a doua schemă de scalare conduce la performanțe superioare.

2.1.4.3. Alegerea parametrilor MLP

În general, este acceptată ideea că MLP poate aproxima cu o precizie foarte bună orice funcție continuă neliniară, însă cu prețul creșterii dimensiunilor rețelei [Lippmann 87], [Hush 93]. Teorema lui Kolmogorov dă și structura unui asemenea MLP: $(M; 2M+1; N)$, M și N reprezentând numărul de elemente din primul strat (care nu efectuează procesări), respectiv, din ultimul strat.

Numărul neuronilor din stratul de intrare depinde de specificul problemei, în particular, de numărul de intrări considerate, în aplicația respectivă. Dimensiunile stratului de ieșire depind, de asemenea, de specificul problemei, precum și de alți factori, cum ar fi: tipul mărimilor de ieșire (analogice sau binare), existența sau

absența unei ieșiri speciale pentru semn etc. Într-un cuvânt, numărul neuronilor din stratul de ieșire depinde de forma și de structura, în care se doresc a fi prezentate estimările pentru mărimile de ieșire.

În privința numărului neuronilor din stratul ascuns, în determinarea acestuia, în afara teoremei lui Kolmogorov, intervin și alte considerente. În principiu, se recomandă ca, pe cât posibil, să se folosească un număr cât mai mic de neuroni ascunși, deoarece fiecare asemenea neuron multiplică numărul conexiunilor. Totodată, numărul neuronilor din stratul ascuns poate fi apreciat în funcție de dimensiunea exemplarelor de intrare, N_{comp} [Cârțină 01/2].

În majoritatea cazurilor, dimensiunea rețelei se determină prin încercări succesive. O asemenea metodă pornește de la dimensiunile minime posibile ale MLP, măbind numărul neuronilor, pînă cînd se constată plafonarea performanțelor rețelei. În acest caz, fiecare rețea, de o anumită dimensiune, este antrenată separat. O altă posibilitate este așa numita “**dezvoltare a rețelei**”, care pornește de la un singur neuron ascuns și, pe durata antrenării, creează neuroni suplimentari, în măsura în care prezența acestora contribuie la îmbunătățirea performanțelor rețelei. Acest procedeu este cunoscut sub numele de “**Cascade Correlation**”.

Un alt parametru, care influențează într-o mare măsură performanțele RNA, este rata de învățare, η . De obicei, pentru acest parametru se adoptă inițial valori mici, de ordinul 0,05 pînă la 0,25, pentru a asigura orientarea și apropierea rețelei de soluția problemei. Asemenea valori ale ratei de învățare conduc la un număr mare de iterații (cicluri), dar, cel mai adesea, acesta este prețul care trebuie plătit pentru obținerea performanțelor dorite. De menționat că, în unele cazuri, este utilă creșterea valorii lui η , în cursul antrenării. Mărirea ratei de învățare, pe măsură ce eroarea rețelei scade, contribuie adesea la accelerarea convergenței. Nu se recomandă, însă, utilizarea unor valori prea mari, deoarece acestea ar putea conduce la oscilații în jurul valorii de minim, fără ca acesta să poată fi atins.

O altă creștere a vitezei de convergență este actualizarea ponderilor, folosind un termen adițional, numit **moment**, care ține seama de corecția ponderilor în iterația anterioară:

$$W_{ij}(t+1) = W_{ij}(t) + \eta \cdot \delta_j \cdot o_i + \alpha \cdot \Delta W_{ij}(t) \quad (2.30)$$

iar metoda definită de această relație se numește “**retropropagare cu moment**” (**Backpropagation with Momentum**). Trebuie să observăm din analiza rel. (2.30), că metoda respectivă este o variantă a metodei gradientului conjugat.

Odată ce rețeaua se “așează” pe un minim, indiferent dacă acesta este local sau global, potrivit criteriului de oprire, algoritmul de învățare se întrerupe. Totuși, dacă este vorba despre un minim local, este foarte probabil ca eroarea la ieșirea rețelei să fie inacceptabil de mare.

Dacă însă RNA furnizează o soluție acceptabilă, din punct de vedere al erorii, nu contează dacă minimul este local sau global, și nici măcar dacă antrenarea a fost oprită într-un anumit punct, înainte ca un adevărat minim să fi fost atins.

Dacă nu se dețin informații pertinente asupra ordinului de mărime al ponderilor W_{ij} , se recomandă inițializarea acestora cu valori mici, în intervalul $(-0,5 ; +0,5)$.

2.1.5. Perspectivele RNA

O serie de proiecte de amploare în domeniul RNA s-au finalizat, iar o altă serie se află în curs de desfășurare, durata lor variind de la câțiva ani la un deceniu. Printre acestea din urmă se numără proiectele prognoze și cele ale agenției americane DARPA (Defense Advanced Research Projects Agency).

Proiectul celei de a cincea generații de calculatoare, marcat prin dezvoltarea ingineriei cunoașterii, a fost succedat de proiectul celei de a șasea generații. Acest proiect urmărește realizarea sistemelor **PINK (Psychological/Intelligent/Neural/Knowledge Engineering)**, în cadrul cărora modelele neuronale ocupă un loc important.

O parte dintre predicțiile la viitorul domeniului RNA iau în considerare arhitecturile neuronale și aspectele teoretice legate de acestea [Dumitraș 97]:

- Modelele neuronale vor deveni un instrument esențial în prelucrarea informației;
- Modelele neuronale vor evolua în direcția apariției unor noi interfețe om-mașină; Urmarea va fi integrarea acestora în cadrul sistemelor performante de control, educație, etc.

Printre problemele nerezolvate pînă în prezent, legate de RNA menționăm:

- Unificarea teoriei matematice ce stă la baza RNA;
- Proiectarea arhitecturii optimale “feedforward”;
- Studiul influenței reprezentării informației și a scalării datelor, în problemele reale, asupra performanțelor modelului;
- Studiul stabilității;
- Evaluarea fiabilității oferită de modelele neuronale;
- Integrarea structurilor neuronale în sisteme de prelucrare de mari dimensiuni;
- Realizarea standardizării (terminologie, notații etc).

2.2. Sisteme expert (SE)

2.2.1. Ce este un sistem expert ?

Pornind de la faptul că **Sistemele expert (SE)** câștigă tot mai mult teren în cele mai diverse aplicații din afaceri, știință, inginerie etc, este util să lămurim mai întâi câteva aspecte esențiale legate de aceste forme ale Inteligenței artificiale. Primul pas în reușita rezolvării oricăror probleme, este definirea precisă a ariei sau domeniului problemelor care urmează să fie rezolvate.

Definirea corectă a unui SE este, de regulă, nuanțată după domeniul de utilizare. O definiție generală ar putea fi formulată astfel: **un SE, într-un anumit domeniu, este un set de programe de calcul, care folosind o bază de cunoștințe (și de date) și reguli de inferență, permite rezolvarea unor probleme dificile, a căror abordare pe căi tradiționale ar necesita o experiență umană semnificativă în domeniul respectiv.** Baza de cunoștințe și regulile de inferență sînt modele ale experienței celor mai buni practicieni, capabili să soluționeze problemele respective. Rezultă că un SE este un sistem de calcul, care emulează abilitatea de luare a deciziilor, de către Expertul Uman (EU). Termenul **emulare** indică intenția SE de a acționa întocmai ca un EU, emularea fiind mai restrictivă decît simularea.

Un EU este o persoană care are o experiență semnificativă într-un anumit domeniu și poate soluționa probleme, pe care cele mai multe persoane nu le pot rezolva sau le rezolvă mai puțin eficient.




Fig. 2.8. Conceptul de bază al funcționării unui SE

În Fig. 2.8 se prezintă conceptul de bază al funcționării unui SE. Utilizatorul furnizează SE “fapte” sau alte informații și primește, ca răspuns, “sfaturi” sau “expertize”, adică o soluție pe care SE o indică, la problema precizată prin faptele de intrare.

Apariția SE a fost dictată în primul rînd de următoarele două aspecte:

- dificultatea de a găsi o soluție corectă în problemele ce implică un volum mare de cunoștințe și o căutare lungă;
- dificultatea de a avea la dispoziție mereu și în diferite locuri EU.

SE au un număr de trăsături atractive. Dintre acestea menționăm:

- disponibilitate crescută – producție de masă a expertizei: SE este disponibil în orice moment și nu este afectat de emotivitate, factori de stres;
- reducerea costului – corelat cu punctul precedent;
- reducerea pericolelor – SE poate fi folosit în medii periculoase pentru om;
- creșterea calității, prin obținerea unei expertize complete a domeniului de lucru, ceea ce EU nu face întotdeauna;
- rapiditate, pe sisteme hard și soft adecvate se pot obține performanțe de timp.

Procesul de dezvoltare a unui SE are și un beneficiu indirect. Inițial, cunoștințele există sub formă implicită în mintea EU. Pentru a putea fi introduse în baza de cunoștințe a SE, ele trebuie explicitate. Sub această formă cunoștințele pot fi examinate din punct de vedere al corectitudinii, consistenței și suficienței, ceea ce îmbunătățește calitatea și utilitatea acestora.

2.2.2. Inteligența artificială și Sistemele expert

Pentru a putea defini **Inteligența artificială (IA)**, în mod special cu referire la SE, trebuie să definim mai întâi **inteligența**. Sîntem în cazul unui termen complex și intrat în obișnuință, pentru care încercarea unei definiții precise poate fi și dificilă și lipsită de utilitate. Totuși este important măcar trasarea unei granițe în jurul conceptului respectiv, necesară aici pentru precizarea unor elemente ale IA. Cercetătorii din domeniul IA au căutat să definească inteligența dintr-o perspectivă, care să permită apoi definirea IA. Astfel, s-a arătat că **“un sistem este inteligent, dacă se poate adapta singur la niște situații, are capacitatea de a raționa, adică înțelege legăturile dintre fapte, de a descoperi înțelesuri și de a recunoaște adevărul. Un sistem inteligent poate să învețe, cu alte cuvinte să-și îmbunătățească performanțele pe baza experienței”**. În aceasta definiție sînt cuprinse dezideratele pe care le urmărește IA.

Spre deosebire de IA, **Inteligența naturală sau biologică** este, în sens strict, ansamblul de funcții mentale care au ca obiect cunoașterea conceptuală și rațională.

Inteligența artificială (IA) este arta de a programa calculatoarele, pentru a le determina să realizeze **“lucruri”** care sînt considerate inteligente, atunci cînd sînt făcute de oameni. IA implică, deci, capacitatea de abstracție și de rațiune. Auxiliarul său indispensabil este memoria.

IA urmărește simularea pe calculator a mecanismelor raționamentului uman. În sens larg, IA include anumite aspecte de senzație și de percepție artificială (vederea artificială, înțelegerea limbajului vorbit, etc.) și presupune capacități de învățare și adaptare. În sens restrâns, IA înseamnă arta de a crea medii artificiale care să simuleze procesele cognitive, adică conceptualizarea și raționarea asupra conceptelor.

Cercetările în domeniul IA sînt dominate în prezent de ideile grupate în jurul noțiunii de **Ingineria cunoștințelor** (IC). Această concepție a stat la baza celor mai puternice sisteme inteligente existente astăzi în domenii științifice extrem de variate, ca, de exemplu, spectroscopia moleculară, analiza datelor geologice, planificarea experiențelor genetice și multe altele.

Trebuie subliniat, încă o dată, noutatea fundamentală adusă de SE, și anume faptul că ele operează asupra cunoștințelor și nu asupra datelor, ca sistemele de calcul clasice. Ne aflăm în fața unui nou domeniu de cercetare, în care tehnica de calcul, de ultimă oră, joacă un rol decisiv, domeniu ce se ocupă cu extragerea, explicitarea, reprezentarea, organizarea și folosirea competenței umane, în rezolvarea diferitelor probleme, cu scopul de a construi sisteme capabile să rezolve ele însele asemenea probleme.

După cum se poate observa din Fig. 2.9, în structura unui SE se întîlnesc următoarele componente:

- O **interfață** prin care utilizatorul și SE comunică.
- Un **mediu prin care SE explică** utilizatorului pașii raționamentului său. Acesta se justifică, în faza de dezvoltare a SE, prin necesitatea confirmării corectitudinii însușirii și folosirii cunoștințelor, iar în faza de utilizare, prin importanța și consecințele deciziilor care urmează a fi luate. Se pot depista, în felul acesta, eventualele erori datorate introducerii greșite a cunoștințelor de către operator sau neînțelegerilor dintre inginerul de cunoștințe și EU.
- Un **mediu de achiziție și actualizare** a cunoștințelor.
- Un **motor de inferență**, folosit pentru a decide care reguli sînt satisfăcute, pentru ierarhizarea și executarea acestora, începînd cu regula care are prioritatea cea mai mare.
- O **baza de cunoștințe**, formată din două părți: **baza de reguli** (care conține cunoștințe generale din domeniul de expertiză) și **baza de fapte** (formată din cunoștințele specifice problemei ce se rezolvă).

Ultimele două componente (motorul de inferență și baza de cunoștințe) sînt cele mai importante și caracterizează cel mai bine aceste forme de inteligență artificială, numite SE. Cît despre modul de a construi un astfel de SE, singura soluție este să extragem competența respectivă, să o reprezentăm și să o folosim în program. Această idee ridică, însă, o mulțime de întrebări. În ce constă competența respectivă? Poate fi ea explicitată și formalizată într-un program? Cum putem face programul să

țină seama de ultimele progrese în domeniu? Cum trebuie să interacționeze un expert uman cu un astfel de program? Acestea sînt probleme foarte dificile dar, după cum a demonstrat practica ultimilor ani, rezolvabile.




Fig. 2.9. Structura unui SE

2.2.3. Reprezentarea și procesarea cunoștințelor în SE

2.2.3.1. Reprezentarea cunoștințelor

Sistemele expert sînt sisteme inteligente bazate pe reprezentarea simbolică a cunoștințelor. Ele sînt utile pentru rezolvarea sarcinilor care presupun prelucrarea de simboluri și de semnificații. Astfel de sarcini, cum ar fi planificarea, proiectarea, analiza și diagnoza sînt uneori greu de abordat prin metodele tradiționale, motivul este că ele nu pot fi complet descrise algoritmic.

Reprezentarea cunoștințelor are o mare importanță pentru un SE, din mai multe motive. Unul dintre acestea îl constituie faptul că un SE va fi conceput pentru un anumit tip de reprezentare a cunoștințelor. Pe de altă parte, modul în care un SE reprezintă cunoștințele afectează dezvoltarea, eficiența, viteza de lucru și mentenanța sistemului respectiv. **Cunoștințele** pot fi clasificate în: **procedurale** (a ști cum să faci ceva, adică mijloacele pentru a ajunge la rezultat – un exemplu, cunoașterea dintr-o carte de bucătărie), **declarative** (a ști dacă un enunț este adevărat sau fals – cunoaștere folosită în justiție !) și **subconștiente** (cele din urmă nu pot fi exprimate

prin limbaj, de exemplu: cum știm să mișcăm mâna), iar din punct de vedere al ierarhizării se pot prezenta ca în Fig. 2.10 [Giarranto 94].




Fig. 2.10. Ierarhizarea cunoștințelor

Cunoștințele unui SE sînt formulate, de regulă, într-un limbaj natural. Prin urmare este necesară o modalitate de codificare și procesare a cunoștințelor exprimate în limbajul natural. În plus, cunoștințele EU sînt afectate de ambiguitatea și imprecizia limbajelor naturale. Trebuie considerată, de asemenea, subiectivitatea EU. Aceste aspecte pot fi rezolvate prin folosirea mulțimilor nuanțate și a variabilelor lingvistice [Dumitrescu 99].

Pentru reprezentarea în calculator a cunoștințelor au fost dezvoltate și folosite mai multe formalisme, în funcție de specificul cunoștințelor respective. Dintre acestea menționăm:

- **reguli de producție;**
- **rețele semantice;**
- **frame (cadre).**

Regulile de producție reprezintă o metodă foarte des folosită, aceasta avînd la bază o structură de tip **Condiție (Faptă) ⇒ Acțiune**. Iată un exemplu de acest fel:

IF tensiunea pe bara secundară este scăzută THEN modifică adecvat raportul de transformare al transformatorului din stația respectivă.

În acest caz **condiția (fapta)** este “tensiunea pe bara secundară este scăzută”, iar **acțiunea** este “modifică adecvat raportul de transformare al transformatorului din stația respectivă”. O astfel de regulă specifică acțiunea ce trebuie aplicată, atunci cînd are loc situația descrisă de condiție. Metoda se potrivește situațiilor în care

cunoștințele pot fi modularizate în segmente mici, relativ independente, în care conținutul cunoștințelor este procedural. În cele ce urmează, prin **date** vom înțelege valorile numerice pe care le iau anumite entități fizice, iar, prin **fapte**, descrierile de situații care nu sînt reduse la o formă analitică.

În situațiile în care acest gen de modularizare nu este potrivit și cunoștințele au mai degrabă un caracter declarativ, se folosesc reprezentări de tipul **rețelelor semantice**, adică sisteme complexe de noduri și arce. O reprezentare mai nouă, care realizează, de fapt, o sinteză între primele două, se bazează pe ideea de **frame**. Un **frame (cadru)** este o unitate complexă, ce descrie un prototip al unui obiect sau situații, atît prin modele declarative (prezentînd, de exemplu, atributele obiectului sau situației respective), cît și prin metode procedurale (conținînd, de exemplu, proceduri pentru a executa o serie de inferențe tipice) [Bălăceanu 83].

Pînă în prezent s-a construit o mare varietate de SE, mai mici sau mai mari. SE mari (care conțin mii de reguli), cumulează și cunoștințe nescrise, care pot fi extrase de la EU, prin interviuri intensive, cu ingineri de cunoștințe, pe o perioadă lungă de timp. **Ingineria cunoștințelor**, care stă la baza construirii SE, se referă la achiziționarea cunoștințelor de la EU și din alte surse și la codificarea acestora, în bazele de cunoștințe ale sistemelor respective.




Fig. 2.11. Dezvoltarea unui SE

Etaplele generale în dezvoltarea unui SE sînt prezentate în Fig. 2.11 [Giarratano 94]. Mai întîi, **inginerul de cunoștințe** stabilește un dialog cu EU, în scopul achiziționării cunoștințelor. Acestea sînt codificate în baza de cunoștințe, după care EU evaluează corectitudinea lor și comunică inginerului de cunoștințe corecțiile necesare. Acest proces iterativ continuă pînă cînd EU apreciază ca fiind satisfăcătoare performanțele etapei de achiziționare și ale SE, în ansamblu.

2.2.3.2. Procesarea cunoștințelor

SE sînt foarte diferite de softul convențional, deoarece problemele care se rezolvă uzual cu un SE nu au o soluție algoritmică, în sensul clasic, ci se bazează pe inferență pentru a găsi o soluție rezonabilă (cea mai bună, care poate fi obținută). Principalele metode de inferență sînt [Giarratano 94]: **deducția, inducția, euristica, abstracția, nonmonotonia și analogia.**

În cadrul fiecărui SE, pentru procesarea efectivă a cunoștințelor este necesar un program adecvat, pentru implementarea mecanismului care stă la baza raționamentelor motorului de inferență. Formalizarea cunoștințelor experților, sub formă de reguli, nu este o operație simplă, mai ales cînd aceste cunoștințe n-au fost sistematic explorate. S-ar putea să existe inconsistențe, ambiguități, duplicări sau alte probleme care apar odată cu reprezentarea formală. Mai mult decît atît, adesea EU nu pot explica cum rezolvă problemele; aceștia declară că soluțiile le “vin de la sine”. În acest caz, emularea se bazează pe inducție și RNA.

O limitare practică a multor SE este lipsa de cunoaștere cauzală. Cu alte cuvinte, un SE nu are cu adevărat o înțelegere a cauzelor de bază și a efectelor într-un sistem dat. Este mult mai ușor să se programeze un SE, avînd cunoștințe superficiale, de natură empirică sau euristică, decît avînd cunoștințe profunde. De exemplu, este mai simplă programarea unui SE care să prescrie aspirină pentru durerea de cap, decît programarea tuturor cunoștințelor biochimice, fiziologice și anatomice despre durerea de cap.

Un tip important de cunoștințe superficiale sînt **cunoștințele euristice**, termenul provenind din limba greacă și însemnînd a descoperi. **Euristica** este disciplina ce reunește procedee menite să conducă la descoperire și invenție. Procedeele euristice sînt sisteme operaționale plastice și deschise, de tipul întrebării și punerii de noi probleme, a explorării și ipotezei, a îndoielii față de ceea ce se consideră cu adevărat valabil și contrazicerilor parțiale sau totale. Euristica suscită producția intelectuală divergentă, în care se admit diverse variante și soluții, considerate a fi nu reciproc exclusive, ci complementare. Explorînd integral obiectul cercetării, din anumite puncte de vedere, euristica se lansează apoi în combinatorici din cele mai complexe. Nu se poate face un inventar complet al procedeeleor euristice, decît în raport cu un domeniu dat. Trebuie arătat că, o dată verificate și completate, procedeele euristice se transformă în algoritmi, iar la nivelul ei elementar, euristica rezidă în alegerea algoritmului potrivit, pentru îndeplinirea unei sarcini noi.

Deși euristica nu garantează soluționarea algoritmică a unei probleme, ea conține reguli practice sau cunoștințe empirice, cîștigate pe bază de experiență, care pot ajuta la găsirea unei soluții. Merită subliniat faptul că, în multe domenii, printre care medicina, ingineria, euristica joacă un rol esențial în rezolvarea unor tipuri de probleme, chiar dacă o rezolvare exactă este posibilă. S-ar putea ca aceasta să fie, în

practică, greu de acceptat, din cauza costului ridicat sau lipsei de timp. Euristica poate să ofere “scurtături”, care să reducă timpul și costul găsirii soluției căutate.

În ciuda limitărilor, unele de moment, SE au un mare succes în abordarea unor probleme reale, pe care metodologiile și tehnicile convenționale de programare nu au fost capabile să le rezolve la un nivel satisfăcător, fiind vorba, în special, de acele probleme care folosesc informații nesigure.

Unul dintre cele mai utilizate formalisme de reprezentare și manipulare a cunoștințelor îl reprezintă sistemul bazat pe reguli de producție. Reamintim că în domeniul SE, noțiunea de “**producție**” are o semnificație particulară, deosebită de înțelesul uzual al acestui termen.

Așa cum am mai precizat, baza de cunoștințe a unui SE conține o colecție de adevăruri relevante despre un anumit domeniu și este formată din **Reguli** și **Fapte**. Regulile au forma unei perechi **Condiție (Faptă) $\Rightarrow$ Acțiune**:

IF Condiție THEN Acțiune

Aceste sisteme de reguli au un număr însemnat de avantaje care fac din ele o formă accesibilă de reprezentare a cunoștințelor. Dintre cele mai importante avantaje menționăm:

- simplitatea fiecărei reguli;
- permit separarea efectivă a domeniului cunoștințelor de motorul de inferență;
- satisfac cererea de modularitate;
- au abilitatea de a trata și cunoștințe incerte.

Totodată, sistemul de reguli de producție are și un număr de dezavantaje, dintre care cităm:

- căutarea printr-un set de reguli, în timpul fiecărui pas, devine inefficientă la seturi mari de reguli;
- verificarea și validarea seturilor mari de reguli poate fi extrem de dificilă, din cauza dificultăților de trasare și considerare a interacțiunilor;
- mentenabilitatea seturilor mari este dificilă;
- eficiența abordării, cu factori de certitudine, pe seturi de reguli complexe, este dificil de evaluat etc.

2.2.4. Dezvoltarea și aplicațiile SE

Cu toate succesele obținute în dezvoltarea și îmbunătățirea performanțelor calculatoarelor, rămâne încă o clasă mare de probleme care să fie soluționate de experții umani, numai pe bază de experiență sau raționament bazat pe experiență, în

conjuncție cu rezultatele obținute de analiza numerică și sistemele suport de decizie. Această situație se datorează următoarelor motive:

- Nu este posibil să se dezvolte un model matematic pentru probleme a căror cunoaștere nu este încă încheiată. Adesea cercetătorii recurg la modele simplificate care pot provoca îndoieli, cu privire la valabilitatea rezultatelor.
- O parte din condițiile de funcționare, restricțiile mai ales, nu pot fi întotdeauna formalizate matematic.
- Complexitatea sporită și dimensiunile mari ale unor probleme nu permit obținerea soluțiilor într-un timp rezonabil, din punct de vedere al utilității practice.

Adesea, modulul de acțiune al unui EU se caracterizează printr-un “simț”, care este acumulat treptat, ca rezultat al unei practici îndelungate. Astfel, s-au dezvoltat metodele euristice ca posibilități de abordare în unele situații. Acțiunile operatorilor din dispeceratele centrelor de comandă ale sistemelor energetice, cad de mai multe ori sub asemenea incidențe.

Progresul în SE a fost strâns legat de rezolvarea următoarelor probleme:

- reprezentarea diferitelor tipuri de cunoștințe;
- realizarea practică a mecanismului de inferență;
- realizarea unor structuri adecvate problemelor concrete;
- reprezentarea anumitor incertitudini și imprecizii prin folosirea mulțimilor nuanțate și a variabilelor lingvistice.

Primele SE au apărut în Universități, apoi s-au extins. Institutele/organizațiile angajate prioritar în dezvoltarea SE, sînt: servicii publice, universități, institute de cercetare, întreprinderi [Dillon 90].

Pe baza modelelor din anii '70, s-au dezvoltat cu succes un număr de prototipuri de SE. În felul acesta, SE, care au apărut ca ramură a inteligenței artificiale, pentru studiul procesării cunoștințelor, au ajuns să atingă succese comerciale, prin dezvoltarea unor programe practice de real interes.

Programele de calcul convenționale sînt folosite la rezolvarea unui număr mare de probleme. În general, aceste probleme au soluționare algoritmică și folosesc limbaje avansate de programare. Spre deosebire de acestea, SE sînt concepute să folosească, în principal, raționamentul simbolic. SE pot fi folosite, în principiu, în orice domeniu de cunoștințe. Astfel, s-au realizat deja SE în electronică, energetică, chimie, medicină, inginerie etc, iar realizările respective au în vedere probleme de diagnoză, interpretare, instruire, monitorizare, planificare, remediere, control etc.

Interesul pentru aplicarea SE în energetică a cunoscut, în ultima vreme, o creștere constantă. În energetică, mai ales în analiza sistemelor electroenergetice

(SEE), s-a folosit în decursul timpului o mare varietate de tehnici de calcul, pentru rezolvarea problemelor complexe și de mari dimensiuni.

În evoluția tehnică a domeniului, o etapă deosebită a constituit-o întotdeauna introducerea sistemului SCADA (**Supervisory Control and Data Acquisition**), care permite culegerea și procesarea on-line a datelor; această perioadă corespunde unei dezvoltări explozive a metodelor de conducere on-line. Au apărut estimatorii de stare, de siguranță etc. Dezvoltarea în această perioadă, mai ales, a metodelor de conducere on-line, a fost legată de punerea la punct a modelelor matematice ale sistemelor de urmărire, prin utilizarea unor tehnici sofisticate de control și a programării matematice. Au fost obținute succese importante, iar în unele cazuri și o calitate foarte bună a soluțiilor [Dillon 90], [Cârțină 01/2].

Cu toate aceste succese, punerea la punct a unor aplicații bazate pe SE a constituit și pentru domeniul energetic un impuls în rezolvarea, la un nivel superior și cu eficiență sporită, a unui număr mare de probleme.

Ținând seama de aptitudinea de a reacționa rapid, plecând de la informații numeroase, SE prezintă un interes deosebit în energetică. Ele permit luarea unei decizii adecvate on-line, când timpul de reacție este foarte scurt, sau în afara timpului real, când trebuie examinate multiple scenarii.

Aplicațiile potențiale cu perspectivele cele mai mari în sistemele electroenergetice (SEE), sînt:

- analiza în regim on-line;
- detectarea defectelor;
- conducerea operativă și automatizarea instalațiilor energetice;
- analiza și reconstrucția postavarie a rețelelor electrice;
- mentenanța sistemelor de protecție ale sistemelor energetice;
- conducerea centralelor nucleare;
- planificarea rețelelor de distribuție etc.

Fundamentarea unei aplicații bazate pe SE este o problemă dificilă și complexă și trebuie să pornească de la analiza factorilor care pot afecta succesul implementării: costul de dezvoltare, costul mentenanței, testabilitatea, selecția aplicației etc.

Problematika din energetică, pentru care se are în vedere introducerea SE, în scopul îmbunătățirii funcționării SEE, are anumite particularități, derivate din cerințele ce se impun sectorului energetic (siguranță în funcționare, timp redus de decizie etc), motive pentru care SE se pot dovedi de mare utilitate.

2.3. Logica fuzzy (LF)

2.3.1. Mulțimi fuzzy și Logica fuzzy

Mulțimile fuzzy și Logica fuzzy sînt definite, în 1965, de către Lotfi Zadeh [Zadeh 65], ca instrumente pentru lucrul cu incertitudini non-probabilistice. Primită cu neîncredere la început, **Logica Fuzzy (LF)** în prezent este considerată una dintre cele mai importante teorii ale secolului.

LF formalizează un mod de operare cu elemente care au un anumit grad de incertitudine. Propozițiile și raționamentele în logica fuzzy nu sînt considerate ca fiind în totalitate adevărate sau false. Valoarea de adevăr a aserțiunilor este nuanțată în intervalul $(0,1)$, potrivit unor funcții “de apartenență”. Acest mod de gîndire este caracteristic pentru om, care, în mod obișnuit, nu utilizează simboluri discrete și numere, ci reprezentări calitative și termeni lingvistici.

Ideea de bază a LF este de a modela și de a putea opera cu incertitudini. Modelele matematice și algoritmi folosiți în practică, în general, practica energetică, în particular, tind să fie cît mai aproape posibil de realitate. Dar observațiile, descrierile și abstracțiile făcute în cursul modelării sînt întotdeauna surse de imprecizie. O clasificare a acestor surse de imprecizie și a modelelor care decurg este prezentată în Fig. 2.12 [Steitz 93].




Fig.2.12. Surse de imprecizii în modelele matematice

În timp ce primele două surse de imprecizie (măsurători inexacte, evenimente întâmplătoare/aleatorii) și-au găsit de mult modele matematice corespunzătoare, ultima sursă de imprecizie (descrierea lingvistică), nu, deși noi utilizăm zilnic

expresii de tipul “rețeaua este puțin/slab încărcată” etc. Descrierea lingvistică face parte din modelarea proceselor și din limbajul operatorilor/expertiilor. Cunoștințele acestor experți sînt de regulă formulate într-un limbaj natural. Prin urmare, se impune o modalitate de codificare și manipulare a cunoștințelor exprimate în limbajul natural. Această modalitate ar putea fi bazată pe folosirea mulțimilor nuanțate și a variabilelor lingvistice. Mai mult decît atît, cunoștințele experților sînt afectate de ambiguitatea și imprecizia limbajelor naturale. Ambiguitatea inerentă unor fenomene sau unor concepte ale limbajului natural nu poate fi redusă la o măsură probabilistică.

LF încearcă să rezolve aceste probleme printr-o modelare coerentă a incertitudinilor, oferind totodată posibilitatea de operare cu asemenea modele.

Mulțimile fuzzy sînt legate conceptual de proprietățile intrinseci de incertitudine ale modelului. Ele modelează noțiunea de posibilitate, și anume posibilitățile individuale ale unor obiecte de a fi încadrate într-un concept semantic. O mulțime fuzzy are în vedere implicit:

- un domeniu ce reprezintă populația mulțimii fuzzy;
- reprezentarea semantică asociată populației fuzzy;
- o funcție care definește gradul de apartenență al unui element din domeniu la mulțime.

Dacă X este o mulțime de obiecte și A este un domeniu de proprietăți, mulțimea fuzzy A este formată din perechile:

$$A = \{x, \mu_A(x) \mid x \in X\} \quad (2.31)$$

unde $\mu_A(x)$ este numită **funcția de apartenență**. Valoarea acesteia indică gradul de apartenență a elementului x la A , sau gradul de încredere că elementul x are proprietatea asociată semantic mulțimii respective.

În Fig. 2.13 se exemplifică definiția mulțimilor fuzzy care caracterizează sarcina unui transformator dintr-un PT. Evaluarea sarcinii este făcută în termeni lingvistici:

**VS (Very Small – Foarte Mică), S (Small – Mică), M (Medium – Medie),
H (High – Mare), VH (Very High – Foarte Mare).**

Limitele fiecărui nivel lingvistic se pot cuantifica (în u. r.), pe baza unor studii consistente, ținînd seama de zonă, compoziția sarcinii etc.

Gradul de apartenență a unei valori la unul dintre cei cinci termeni lingvistici este o măsură a conformității valorii cu semnificația clasei lingvistice. Funcția de apartenență oferă deci, o măsură cantitativă, numerică a gradului de adecvare a valorii respective, cu noțiunea semantică respectivă.

Dacă funcția de apartenență ia valori în intervalul (0,1) se spune că este normalizată. Normalizarea funcțiilor de apartenență este recomandată pentru a putea realiza cu acestea operații de Logică fuzzy.




Fig. 2.13. Nivelele lingvistice de sarcină ale unui transformator MT/JT

Setul de elemente care compune o mulțime fuzzy este alcătuit din acele elemente care aparțin domeniului de definiție și au gradul de apartenență la mulțime (gradul de conformitate cu proprietățile mulțimii) mai mare ca zero:

$$S(A) = \{x \in X \mid \mu_A(x) > 0\} \quad (2.32)$$

Mulțimea elementelor care aparțin cel puțin în măsura α mulțimii fuzzy A este numită **setul de nivel α al mulțimii fuzzy A** :

$$A_\alpha = \{x \in X \mid \mu_A(x) \geq \alpha\} \quad (2.33)$$

Asocierea unor semnificații lingvistice pentru un set de valori numerice, obținând astfel un set de mărimi fuzzy, se numește **fuzzificare**. Operația inversă, care asociază unei mărimi fuzzy o valoare numerică precisă, poartă numele de **defuzzificare**.

Fuzzificarea este în general un proces subiectiv, în care operatorul uman atribuie grade lingvistice unui domeniu fizic și stabilește funcții de apartenență în conformitate cu experiența și cunoștințele proprii.

Pentru defuzzificare sînt definite diverse metode care permit obținerea unei valori numerice printr-o expresie ce combină mai multe funcții de apartenență. Una din cele mai cunoscute este **metoda centrului de greutate al suprafeței rezultată prin însumarea valorilor individuale**:

$$x_{selectat} = \frac{\int x \cdot \sum_k (\mu_{Ak}(x)) \cdot dx}{\int \sum_k (\mu_{Ak}(x)) \cdot dx} \quad (2.34)$$

Logica formală sau Logica matematică a fost una dintre primele instrumente de analiză folosite în cadrul Inteligenței artificiale. Ea are în vedere:

- **Calculul propozițiilor** – care studiază legăturile între propoziții fără a ține seama de structura internă a acestora. Operațiile cu propoziții sînt realizate prin intermediul unor operatori logici: negația, conjuncția, disjuncția, disjuncția exclusivă, implicația, echivalența.
- **Calculul predicatelor** – care studiază legăturile între afirmații relative la una sau mai multe variabile dintr-un domeniu de definiție. Afirmațiile relative la una sau mai multe variabile, care au proprietatea că pentru valori specificate ale variabilelor sînt adevărate sau false, se numesc **predicate**. Pentru un predicat trebuie definite atît domeniul de definiție cît și domeniul de adevăr care reprezintă domeniul de valori pentru care satisface condiția cerută de predicat.

Spre deosebire de logica bivalentă, unde gradul de apartenență al unui obiect la grup putea avea două valori, în cadrul Logicii fuzzy, unul dintre sistemele logice care operează cu grade multiple de adevăr, acesta poate avea orice valoare reală cuprinsă în intervalul $[0,1]$. Avantajul major al acestui sistem logic este acela că operează cu mulțimi care prin definiție sînt caracterizate prin funcții de apartenență continue și normate.

Elementul de bază într-un model fuzzy sînt propozițiile. Acestea operează cu variabile fuzzy. Propozițiile fuzzy stabilesc relațiile dintre conotația lingvistic-semantic și domeniul numeric de definiție. Acestea sînt de forma **x este Y**, unde x este o valoare scalară din domeniul numeric, iar Y este conotația lingvistică. Evaluarea măsurii în care propoziția este adevărată se realizează cu ajutorul funcției de apartenență, $\mu_A(x \in Y)$.

Raționamentul fuzzy implică totalitatea legilor și procedurilor care permit determinarea gradului de adevăr al unor inferențe ce au avut ca obiect mulțimi fuzzy. Baza raționamentului fuzzy o constituie **implicația fuzzy**. Din acest motiv problema centrală în dezvoltarea Logicii fuzzy o constituie evaluarea gradului de adevăr al implicațiilor fuzzy.

2.3.2. Alegerea funcției de apartenență

Alegerea formei funcției de apartenență este una din etapele cele mai importante ale lucrului cu mulțimi fuzzy. Pentru o alegere cât mai corectă se estimează/ calculează pentru variabila respectivă valorile minimă și maximă, pe baza experienței decidentului, **Decision-Making (DM)**. Plecând de la aceste valori, DM stabilește alina funcțiilor de apartenență [Chen 94]. În această operație de stabilire a funcției de apartenență ar trebui să fie înglobată experiența specialiștilor din domeniu (operatori sau dispeceri din cadrul sistemului energetic, de exemplu) [Rahman 94].

Deși în principiu, pentru funcția de apartenență, poate fi considerată orice formă de funcție, cele mai folosite sînt de tipul: **funcție liniară**, Fig. 2.14, **liniară pe porțiuni**, Fig. 2.15, **hiperbolică**, Fig. 2.16, **triunghiulară**, Fig. 2.17, **trapezoidală**, Fig. 2.18 sau **gaussiană**, Fig. 2.19. Valorile funcției de apartenență sînt normalizate în intervalul $[0,1]$.




Fig. 2.14. Funcție liniară




Fig. 2.15. Funcție liniară pe porțiuni




Fig. 2.16. Funcție hiperbolică




Fig. 2.17. Funcție triunghiulară




Fig. 2.18. Funcție trapezoidală




Fig. 2.19. Funcție gaussiană

În cazul formei triunghiulare și trapezoidale, în mod uzual funcția de apartenență este reprezentată prin "breaking points", Fig. 2.17, Fig. 2.18:

$$\tilde{A} = (X_1, X_2, X_3) = [m, a, b] \quad (2.35)$$

$$\tilde{A} = (X_1, X_2, X_3, X_4) = [m, n, a, b] \quad (2.36)$$

O formă deosebit de atractivă de funcție de apartenență este dată de relația (2.37). Alături acestei funcții pentru diferite valori ale exponentului n este prezentată în Fig. 2.20.

$$\mu(X) = \frac{1}{1 + X^{2n}} \quad X = \frac{x - a}{b} \quad (2.37)$$

unde a, b sînt parametri.




Fig. 2.20. Reprezentarea funcției (2.37)

Faptul că derivatele acestei funcții se calculează foarte ușor, rel. (2.38), (2.39), poate fi folosit în cadrul proceselor iterative, la determinarea soluțiilor în optimizarea multiobiectiv.

$$\mu' = -\frac{2n}{b} \mu^2 \left(\frac{1-\mu}{\mu} \right)^{\frac{2n-1}{2n}} \text{sign}(s-a) \quad (2.38)$$

$$\mu'' = \frac{2n}{b^2} \mu^2 \left(\frac{1-\mu}{\mu} \right)^{2n-2} (2 \cdot 2n \mu \left(\frac{1-\mu}{\mu} \right)^{2n} - (2n-1)) \quad (2.39)$$

Asociind facilitatea în obținerea derivatelor cu posibilitatea alegerii parametrilor a și b , relația (2.37), funcția de apartenență respectivă poate să satisfacă numeroase cerințe întâlnite frecvent în optimizarea multicriterială.

Este util să menționăm că funcțiile de apartenență se pot întâlni și sub forma din Fig. 2.21 [Hsu 92/1-2], adică nu este obligatorie atingerea valorii maxime (1) pentru toate categoriile lingvistice.

Stabilirea celor cinci variabile lingvistice pe baza unui **indice de gravitate (SI)** este utilă la aprecierea circulațiilor de puteri pe liniile electrice în analizele postcontingență. O valoare mare a indicelui de gravitate indică un risc foarte mare al depășirii limitelor admisibile ale circulației de putere pe linie și existența unei stări de insecuritate.




Fig. 2.21. Funcțiile de apartenență pentru cele cinci variabile lingvistice ale lui SI

2.3.3. Operații cu numere (mulțimi) fuzzy

Operațiile cu mulțimi fuzzy reprezintă operații cu funcțiile lor de apartenență. Operațiile algebrice obișnuite cu numere (mulțimi) reale pot fi extinse la operații cu numere (mulțimi) fuzzy, folosind **Principiul de Extindere**, formulat de Zadeh [Teodorescu 89]. Astfel, date fiind mulțimile $\tilde{A}$ și $\tilde{B}$ (relația 2.40), adunarea lor ($\tilde{A} + \tilde{B}$) se calculează cu relațiile (2.41) și (2.42), iar produsul cu, (2.43) și (2.44). Relațiile (2.45) și (2.46) dau produsul dintre un număr (mulțime) fuzzy $\tilde{A}$ și o constantă reală c [Cârțină 01/2]:

$$\tilde{A} = \{ (x_1, \mu_{\tilde{A}}(x_1)), x_1 \in X \} \quad (2.40)$$

$$\tilde{B} = \{ (y_1, \mu_{\tilde{B}}(y_1)), y_1 \in X \}$$

$$\tilde{A} + \tilde{B} = \{ (z_1, \mu_{\tilde{A}+\tilde{B}}(z_1)), z_1 \in X \} \quad (2.41)$$

$$\mu_{\tilde{A}+\tilde{B}}(z_1) = \max_{z_1=x_1+y_1} \{ \min [\mu_{\tilde{A}}(x_1), \mu_{\tilde{B}}(y_1)] \} \quad (2.42)$$

$$\tilde{A} \cdot \tilde{B} = \{ (z_1, \mu_{\tilde{A} \cdot \tilde{B}}(z_1)), z_1 \in X \} \quad (2.43)$$

$$\mu_{\tilde{A} \cdot \tilde{B}}(z_1) = \max_{z_1=x_1 \cdot y_1} \{ \min [\mu_{\tilde{A}}(x_1), \mu_{\tilde{B}}(y_1)] \} \quad (2.44)$$

$$c \cdot \tilde{A} = \{ (x_1, \mu_{c \cdot \tilde{A}}(x_1)), x_1 \in X \} \quad (2.45)$$

$$\mu_{c \cdot \tilde{A}}(x) = \mu_{\tilde{A}}(c \cdot x) \quad (2.46)$$

Având în vedere faptul că reprezentarea numerelor (mulțimilor) fuzzy prin “**breaking points**” este foarte frecventă, vom defini operațiile de adunare, înmulțire, împărțire și radical dintr-un număr fuzzy, plecând de la această formă de reprezentare.

Dacă pentru trei mulțimi (numere fuzzy) adoptăm pentru funcția de apartenență forma trapezoidală, reprezentată prin “**breaking points**”, Fig. 2.18,

$$\tilde{A} = [m_1, n_1, a_1, b_1]; \tilde{B} = [m_2, n_2, a_2, b_2]; \tilde{C} = [m_3, n_3, a_3, b_3] \quad (2.47)$$

pentru operațiile de adunare și înmulțire avem relațiile (2.48), respectiv, (2.49) [Steitz 93]:

$$\tilde{A} + \tilde{B} + \tilde{C} = [m_2 + m_3, n_2 + n_3, a_2 + a_3, b_2 + b_3] \quad (2.48)$$

$$\begin{aligned} \tilde{A} \cdot \tilde{B} &= [m_1, a_1, b_1] = \tilde{B} \cdot \tilde{C} = \\ &[m_2 m_3, n_2 n_3, m_2 a_3 + m_3 a_2 - a_2 a_3, n_2 b_3 + n_3 b_2 + b_2 b_3] \end{aligned} \quad (2.49)$$

În cazul particular al funcției de apartenență triunghiulară, $m = n$, iar relațiile precedente devin:

$$\tilde{A} + \tilde{B} + \tilde{C} = [m_2 + m_3, a_2 + a_3, b_2 + b_3] \quad (2.50)$$

$$\tilde{A} \cdot \tilde{B} = [m_1, a_1, b_1] = \tilde{B} \cdot \tilde{C} = [m_2 m_3, m_2 a_3 + m_3 a_2 - a_2 a_3, m_2 b_3 + m_3 b_2 + b_2 b_3] \quad (2.51)$$

Plecînd de la relațiile de mai sus, în vederea definirii operației de radical dintr-un număr fuzzy, facem:

$$m_3 = m_2, \quad a_3 = a_2, \quad b_3 = b_2 \quad (2.52)$$

de unde rezultă sistemul de ecuații (2.53) – (2.55):

$$m_2^2 = m_1 \quad (2.53)$$

$$2m_2a_2 - a_2^2 = a_1 \quad (2.54)$$

$$2m_2b_2 + b_2^2 = b_1 \quad (2.55)$$

din care deducem expresiile necunoscutele m_2 , a_2 și b_2 :

$$m_2 = \sqrt{m_1} \quad (2.56)$$

$$a_2 = \sqrt{m_1} \pm \sqrt{m_1 - a_1} \leq \sqrt{m_1} \quad (2.57)$$

$$b_2 = -\sqrt{m_1} \pm \sqrt{m_1 + b_1} \geq 0 \quad (2.58)$$

Ținînd seama de condițiile (2.57) – (2.58), unde se vor alege variantele convenabile, în final, pentru operația de radical dintr-un număr (mulțime) fuzzy:

$$\sqrt{\tilde{A}} = [\sqrt{m_1}, \sqrt{m_1} - \sqrt{m_1 - a_1}, -\sqrt{m_1} + \sqrt{m_1 + b_1}] \quad (2.59)$$

În mod cu totul similar, pentru operația de împărțire a numerelor (mulțimilor) fuzzy, din relația (2.51) avem sistemul de ecuații (2.60) – (2.62):

$$m_2m_3 = m_1 \quad (2.60)$$

$$m_2a_3 + m_3a_2 - a_2a_3 = a_1 \quad (2.61)$$

$$m_2b_3 + m_3b_2 + b_2b_3 = b_1 \quad (2.62)$$

din care se determină necunoscutele m_3 , a_3 , b_3 :

$$m_3 = \frac{m_1}{m_2} \quad (2.63)$$

$$a_3 = \frac{a_1 - \frac{m_1}{m_2} a_2}{m_2 - a_2} \geq 0 \quad (2.64)$$

$$b_3 = \frac{b_1 - \frac{m_1}{m_2} b_2}{m_2 + b_2} \geq 0 \quad (2.65)$$

Ținând seama de semnificația parametrilor respectivi, Fig. 2.17, condițiile (2.64) – (2.65) se mai pot scrie:

$$\frac{a_1}{a_2} > \frac{m_1}{m_2}; \quad \frac{b_1}{b_2} > \frac{m_1}{m_2} \quad (2.66)$$

Așa cum am mai precizat, necesitatea introducerii numerelor (mulțimilor) fuzzy a plecat de la folosirea pe scară largă a descrierilor lingvistice, făcute, mai ales de experți, dar nu numai.

Cunoștințele experților sînt afectate de ambiguitatea și imprecizia limbajelor naturale. În plus, subiectivitatea diferiților experți este un factor important, care trebuie avut în vedere în procesarea cunoștințelor respective.

Raționamentul aproximativ (bazat pe mulțimi nuanțate și variabile lingvistice) poate modela raționamentul uman. Utilizarea raționamentului aproximativ în sistemele expert poate să crească eficiența (prin descreșterea timpilor de răspuns, ușurința de a introduce noi reguli și cunoștințe etc).

Logica fuzzy a fost, cum s-a mai subliniat anterior, dezvoltată de Zadeh în deceniul al șaselea al secolului trecut, pentru reprezentarea incertitudinii și a cunoștințelor imprecise. Ea reprezintă un instrument aproximativ, dar eficace de descriere a comportării sistemelor care sînt fie prea complexe, fie imprecis definite sau dificil de analizat matematic.

LF implică **fuzzificarea**, **inferența fuzzy** și **defuzzificarea**. Fuzzificarea convertește o valoare de intrare crisp, într-una fuzzy. Inferența fuzzy permite deducerea concluziilor pe bază de cunoștințe, iar defuzzificarea convertește acțiunea de control fuzzy, într-o acțiune crisp.

Gîndită pentru a lucra cu date incerte, Logica fuzzy se poate aplica în majoritatea domeniilor de activitate, dintre care, nu în ultimul rînd, în controlul proceselor din industria energetică. Controlul și reglarea proceselor industriale sînt domeniile în care Logica fuzzy își găsește un teren propice de aplicare. Aceasta se datorează simplității și parametrizării reguletoarelor respective, care pot depăși astfel performanțele reguletoarelor clasice.

Una dintre cele mai importante aplicații ale acestor tehnici fuzzy constă în rezolvarea problemelor de optimizare multicriterială. Simplitatea modelului de optimizare fuzzy și a algoritmilor de soluționare constituie avantaje foarte atractive.

Trebuie menționat faptul că folosirea tehnicilor fuzzy în rezolvarea problemelor de optimizare multicriterială reprezintă un pas înainte, în raport cu tehnicile precedente, care nu dădeau satisfacția corespunzătoare. Este însă necesar să subliniem cu această ocazie că rolul expertului, **Decision-Making (DM)**, este fundamental în alegerea funcțiilor de apartenență pentru diferitele criterii de optimizare implicate și pentru forma funcției globale de optimizare.

De asemenea, Logica fuzzy se aplică pe larg în domeniul sistemelor expert care lucrează cu date incerte și cu reguli de interferență nuanțate. Se poate menționa în acest sens **Fuzzy CLIPS**, un produs software care permite generarea unor sisteme expert bazate pe Logica fuzzy.

2.4. Algoritmi genetici (AG)

2.4.1. Limitele metodelor tradiționale de optimizare

Dorința umană de perfecțiune își găsește expresia în teoria optimizării. Aceasta cuprinde studiul cantitativ al punctelor de optim și metodele găsirii lor. Optimizarea caută ameliorarea unei performanțe, prin apropierea iterativă de punctul (punctele) de optim.

Este evident că trebuie să distingem procedeul de ameliorare, de destinația sa, optimum propriu-zis. Obiectivul cel mai important al optimizării este ameliorarea. Prioritar este să se atingă cât mai rapid o performanță de nivel satisfăcător. Găsirea optimului (absolut) este mult mai puțin importantă pentru sistemele complexe reale. Ar fi foarte bună atingerea perfecțiunii, dar cel mai adesea ne putem mulțumi și cu o ameliorare [Goldberg 94].

Cele mai multe probleme de optimizare se rezolvă numeric folosind **metode iterative**, Fig. 2.22. Acestea pornesc de la o soluție inițială (de regulă, aleasă arbitrar) și determină la fiecare pas o soluție mai bună (mai aproape de optim).

Metode iterative	1.1. Căutare directă	1.1.1. Căutare exhaustivă
		1.1.2. Ameliorare iterativă
		1.1.3. Căutare probabilistică
	1.2. Coborîre	1.2.1. Gradient
		1.2.2. Newton etc.

Fig. 2.22. Metodele iterative de optimizare

Metodele de căutare exhaustivă iau în considerare toate posibilitățile de exploatare a spațiului problemei, păstrînd la fiecare pas soluția corespunzătoare celei mai bune valori a funcției obiectiv. Căutarea se termină la epuizarea tuturor elementelor din spațiul stărilor.

Metodele de ameliorare iterativă folosesc evaluarea funcției obiectiv în vecinătatea punctului curent, iar **metodele probabilistice (pseudoaleatoare)** realizează modificări pseudoaleatoare în jurul punctului curent.

Metodele de coborîre sînt cele mai folosite proceduri de optimizare. În fiecare etapă a procedurii se calculează o nouă direcție de căutare (pe baza cunoașterii gradientului local) și un nou pas (optimal) de deplasare, pe direcția respectivă. Dintre aceste metode cele mai folosite sînt: **metoda gradientilor conjugați**, **metoda Newton**, **cvasi Newton** etc.

Dacă metodele de căutare directă sînt lente și cu eficiență redusă, metodele de coborîre, deși performante, nu pot fi aplicate întotdeauna. Cerințele de continuitate, derivabilitate, etc. sînt foarte restrictive și nu sînt satisfăcute adesea. În asemenea situații, dacă ne mulțumim cu o soluție, nu în mod obligatoriu optimală, **Calculul Evolutiv (CE)** poate constitui un instrument de rezolvare a problemelor respective.

Tehnicile CE au fost inițial dezvoltate pentru rezolvarea unor probleme de optimizare complicate, a căror abordare prin mijloace tradiționale era imposibilă. Se poate vorbi de acele situații în care ne mulțumim să găsim o soluție a problemei, fără a pretinde ca aceasta să fie neapărat o soluție optimală, iar funcția obiectiv nu satisface condițiile de continuitate și derivabilitate etc.

Metodele dezvoltate de CE sînt generale, independente de problemă și de funcția ce se dorește optimizată (funcția criteriu).

2.4.2. Algoritmii genetici (AG)

Calculul evolutiv cuprinde o colecție de algoritmi bazați pe tehnici euristice inspirate de evoluția biologică/naturală. Acești algoritmi pot fi aplicați cu succes în probleme de optimizare multicriterială. Populația unei posibile soluții evoluează de la o generație, la următoarea, pe baza principiului "**supraviețuirii**", conform căruia indivizii cu puterea de adaptare cea mai mare au cele mai mari șanse de a lăsa urmași. În ciuda faptului că aceste tehnici au fost clasificate în trei categorii distincte [Jain 99]:

- Algoritmi genetici,
- Strategii de evoluție,
- Programarea evolutivă,

această clasificare are la bază mai degrabă detalii de dezvoltare istorică, decît diferențe funcționale majore.

Deși detaliile evoluției biologice nu sînt încă complet elucidate, din perspectiva interesului pentru acest domeniu este util să menționăm anumite caracteristici:

1. Cromozomii sînt purtătorii de informație genetică.
2. Fiecare individ al unei specii posedă un număr determinat de cromozomi. Totalitatea cromozomilor unui individ reprezintă **genotipul (genomul)** său.
3. Cromozomii sînt structuri liniare alcătuite din **gene**. Genele poartă caracteristicile ereditare.
4. Evoluția este un proces care operează la nivelul cromozomilor.

AG sînt o procedură iterativă care lucrează asupra unei populații de mărime constantă, fiecare individ fiind reprezentat printr-un șir liniar finit de simboluri, numit **genom**, și care codifică o soluție posibilă în spațiul problemei.

Pentru rezolvarea unei probleme de optimizare cu ajutorul AG este necesară codificarea mărimilor cu care se operează (cromozomi), sub forma unor șiruri de lungime finită, care conțin caractere dintr-un anumit alfabet. De asemenea, este necesară definirea, de către utilizator, a unei **funcții de performanță (adecvare)** pentru fiecare cromozom. Funcția de adecvare respectivă trebuie să fie destul de rapid calculabilă, avînd în vedere procedura de evaluare repetată, în cadrul algoritmilor respectivi. Pe baza evaluării, fiecărui cromozom i se atribuie un **fitness (fitness value)**, definit printr-o relație de tipul:

$$\frac{f_i}{f_m} = \text{valoare asociată cromozomului} / \text{valoarea medie asociată cromozomilor}$$

AG lucrează simultan asupra unei populații de soluții potențiale (cromozomi), distribuite pe întreg spațiu de căutare.

Dinamica procesului de căutare generat de un AG se realizează prin combinarea și modificarea cromozomilor. La fiecare iterație a algoritmului se creează o nouă populație, numită **generație**. Toate generațiile au același număr de cromozomi. Admișînd că noua generație constă din cromozomi mai performanți, cu succesiunea generațiilor se va înregistra o tendință de evoluție a acestora spre optimul global al funcției de adecvare.

Obținerea unei noi generații, plecînd de la precedentă, se face prin folosirea operatorilor genetici (selecție, încrucișare și mutație) și are loc în trei etape:

1. **Evaluarea.** AG calculează funcția de adecvare pentru fiecare individ al vechii populații.
2. **Selecția cromozomilor-părinți.** AG selecționează cromozomii-părinți dintr-o populație $P(t)$, în funcție de performanțele lor. Selecția se face prin metoda **ruletei**; fiecare cromozom fiind reprezentat proporțional cu fitnessul său. Un alt procedeu de selecție este “**extragerea aleatorie cu rest**”. Pentru fiecare

cromozom, la care fitnessul este supraunitar, partea întreagă a fitnessului reprezintă numărul de șiruri identice care vor fi plasate în populația intermediară P^1 . Toate șirurile cu fitnessul subunitar plasează în P^1 copii adiționale cu probabilități corespunzătoare părții fracționare. Păstrarea celui mai bun individ la fiecare generație poartă numele de **strategie elitistă**.

3. **Recombinarea și mutația.** AG modifică populația selecționată P^1 prin operatorii genetici de încrucișare/recombinare și mutație genetică. Pentru operația de încrucișare se aleg doi cromozomi-părinți care, în urma încrucișării, dau naștere la doi cromozomi-urmași, ce trec în generația următoare. Punctul de încrucișare se alege în mod aleatoriu, după care cromozomii-părinți schimbă între ei secvența de gene situate în dreapta punctului respectiv. Când se folosesc cromozomi de lungimi mari, se poate proceda la încrucișarea în mai multe puncte.

Pentru a ține seama de caracterul probabilistic al operației respective, aceasta este controlată de așa-numita **rată de încrucișare** R_i . În acest sens, după alegerea cromozomilor părinți, înaintea determinării punctului de încrucișare, se generează un număr aleator r , în intervalul $(0,1)$, iar încrucișarea propriu zisă are loc numai dacă $r < R_i$. R_i este de ordinul $0,005 \div 0,03$, la fiecare iterație producându-se doar câteva încrucișări.




Fig. 2.23. Exemplificarea mecanismului de încrucișare

Pentru extinderea, în continuare, a subspațiului de căutare și deci pentru evitarea opririi într-un punct de extrem local, cromozomii-urmași, rezultați în urma încrucișărilor, sînt supuși mutațiilor genetice. În cazul codificării binare a cromozomilor, mutația se realizează prin alegerea aleatorie a unei gene și bascularea acesteia în cealaltă valoare binară $(0,1)$.

Ca și în cazul încrucișărilor, mutațiile se execută numai dacă un număr, generat aleatoriu în intervalul $(0,1)$, este mai mic decît o valoare prescrisă pentru **rata mutațiilor** R_m . Valoarea lui R_m este de ordinul 10^{-5} , o mutație avînd loc la câteva sute de mii de iterații.

Pentru Algoritmii genetici există mai multe variante. În alegerea variantelor trebuie să se țină seama și de natura problemei ce trebuie rezolvată.

Etapele algoritmului genetic fundamental (canonic) sînt prezentate în Fig. 2.24.

- **P1.** $t = 0$;
- **P2.** Se inițializează populația $P(t)$;
- **P3.** Se evaluează funcțiile de adecvare pentru cromozomii populației $P(t)$;
- **repeat**
 - **P4.** Se aplică operatorul de selecție de n ori. Cromozomii selectați formează o populație intermediară P^1 (avînd tot n membri). În P^1 , unii cromozomi din $P(t)$ pot avea mai multe copii (vor apare de mai multe ori), iar alții nici o copie;
 - **P5.** Asupra cromozomilor din populația intermediară P^1 se aplică operatorul de încrucișare;
Cromozomii nou obținuți formează o populație P^2 ;
Se șterg din populația intermediară P^1 părinții cromozomilor obținuți prin încrucișare;
Cromozomii rămași în P^1 devin și ei membri ai populației P^2 ;
 - **P6.** Asupra populația P^2 se aplică operatorul de mutație.
Rezultatul este noua generație $P(t + 1)$;
 - **P7.** Evaluarea funcțiilor de adaptare pentru populația $P(t + 1)$;
 - **P8.** Se pune $t := t + 1$;
- until {Condiție de oprire}**
- Soluția optimală corespunde cromozomului cu funcția de adecvare maximă din populația $P(t + 1)$.

Fig. 2.24. Etapele algoritmului genetic fundamental (canonic)

Teoria optimizării s-a bazat, într-o primă etapă, pe dezvoltările matematice ale secolului XVIII și XIX, în care “lumea” era curată, alcătuită din funcții pătratice, cu restricții ideale și derivabilitate omniprezentă. Dar “lumea” reală este invadată de discontinuități, spații și soluții perturbate, care se pretează cu dificultate proceselor iterative de determinare a soluțiilor optimale. De aceea optimizarea bazată doar pe calcule matematice nu poate fi aplicată totdeauna [Goldberg 94].

Un alt domeniu în care se pot aplica cu succes algoritmii genetici privește optimizarea multicriterială. Impreună cu Logica fuzzy, tehnica Algoritmilor genetici face posibilă rezolvarea unor asemenea probleme de optimizare, în care intervin mai multe funcții obiectiv, de regulă, noncomensurabile. În energetică sînt numeroase astfel de cazuri.

Rețelele neuronale artificiale, Sistemele expert, Logica fuzzy și Algoritmii genetici au demonstrat posibilitatea de rezolvare a multor probleme, dar nu sînt destul de abile pentru a rezolva probleme reale complexe, precum modelele biologice. Pentru a remedia parțial acest neajuns este utilă fuziunea tehnicilor respective în sisteme complexe de tip neuro-fuzzy etc, pentru a compensa reciproc deficiențele parțiale. Există deja numeroase aplicații precum: RNA pentru proiectarea sistemelor fuzzy, sisteme fuzzy pentru proiectarea RNA, AG pentru proiectarea sistemelor fuzzy, AG pentru învățarea automată și generarea de arhitecturi RNA etc [Jain 99].

Progresele realizate în domeniul energiei au generat nevoi sporite, potrivit cărora se impune ameliorarea calculelor de rutină, dar mai ales trierea datelor, realizarea unor sarcini complexe (analize selective, optimizarea multicriterială, conducerea optimă on-line etc). Se constată că rezolvarea unor probleme practice, legate de exploatarea sistemelor electroenergetice poate face apel la soluții bazate pe una sau mai multe forme de IA.

Caracteristicile esențiale enumerate mai sus, asociate cu rezultatele bune obținute au incitat grupe de cercetători la dezvoltarea unor aplicații care să rezolve sarcinile complexe puse de exploatarea sistemelor electroenergetice.

Bibliografie

- [Alexandrescu 99] Alexandrescu, V., Cârțină, Gh., Bîrlădeanu, E., Bonciu, Cl., Fuzzy Load Modeling in Distribution Networks Analysis, Proc. of the 22nd Seminar of Fundamentals of Electrotechnics and Circuit Theory, SPETO'99, 1999, Gliwice-Ustron, Polonia, pp. 357 - 360.
- [Bălăceanu 83] Bălăceanu, M., Probleme de arhitectură și reprezentare a cunoștințelor în sistemele expert, în Inteligența artificială și robotică, Ed. Academică, București, 1983.
- [Bonciu 99] Bonciu, C., Contribuții la analiza regimului dinamic al sistemelor neuronale artificiale, Teză de doctorat, Universitatea Tehnică "Gh. Asachi", 1999. Iași.
- [Carvalho 00] Carvalho, P., Ferreira, L.A., Lobo, F.G., Barruncho, L.M., Distribution Network Expansion Planning Under Uncertainty: A Headging Algorithm in Evolutionary Approach, IEEE Trans. on Power Delivery, 2000, Vol. 15, No. 1, pp. 412 - 416.
- [Cârțină 94] Cârțină, Gh., Georgescu, Gh., Gavrilăș, M., Bonciu, Cl., Rețelelor neuronale artificiale și sisteme expert în energetică, Editura "Gh. Asachi", Iași, 1994.
- [Cârțină 96] Cârțină, Gh., Georgescu, Gh., Gavrilăș, M., Bonciu, C., Alexandrescu, V., Neural Solutions to the Voltage Violation Problem in On-Line Contingency Analysis, ELECTRIMACS'96, 1996, Saint-Nazaire, Franța, Vol. 2, pp. 365 - 368.
- [Cârțină 98/1] Cârțină, Gh., Bonciu Cl., Mușat M., Zisman Z., Losses Mimimization in Power System Using Artificial Neural Networks, Proc. of the 9th Mediterranean Electrotechnical Conference, MELECON'98, 1998, Tel-Aviv, Israel, Vol. 2, pp. 1103 - 1106.
- [Cârțină 98/2] Cârțină, Gh., Alexandrescu, V., Poată, A., Mușat, M., Optimal Planning of Distribution Networks Using a Fuzzy Approach, Proc. of the 21st Seminar on Fundamentals of Electrotechnics and Circuit Theory, SPETO'98, 1998, Gliwice-Ustron, Polonia, pp. 431 - 434.
- [Cârțină 99/1] Cârțină, Gh., Tănasă, C., Poiată, T., Environment Consideration in the Planning of the Electric Networks, International Conference on Electric Power Engineering, IEEE Power Tech'99 Conference, 1999, Budapesta, Ungaria, Lucrarea BPT99-320-52.
- [Cârțină 99/2] Cârțină, Gh., Alexandrescu, V., Bonciu, Cl., Bîrlădeanu, E., Coordination of Voltage/Reactive Power Control Using Fuzzy

CAPITOLUL 3

TEHNICI DE GRUPARE SPAȚIALĂ ÎN OPTIMIZĂRI

3.1. Aspecte generale privind gruparea spațială

Gruparea spațială (clustering, în engleză) este o tehnică specială de aranjare a datelor de intrare pe baza dispunerii spațiale a vectorilor corespunzători. Pentru a studia asemănarea/deosebirea dintre elementele unei mulțimi, în vederea grupării, fiecare dintre aceste elemente este definit printr-un vector, ale cărui componente sînt chiar caracteristicile/atributele reprezentative ale vectorului respectiv. Stabilirea numărului de componente/tribute și definirea acestora se face în funcție de scopul studiului, datele disponibile și, nu în cele din urmă, în funcție de experiența analistului. În faza următoare, pentru determinarea asemănării/deosebirii dintre elementele implicate se calculează distanța dintre vectorii corespunzători [Jain www].

În cadrul unui astfel de proces, vectorii de intrare sînt grupați în funcție de distanța care separă punctele reprezentative. În urma procesului de grupare spațială rezultă una sau mai multe grupe, în funcție de situație, care reprezintă poziționarea spațială a proprietăților considerate pentru elementele supuse grupării. În interiorul unei asemenea grupe punctele sînt mai apropiate între ele sau în raport cu un centru comun, decît în raport cu centrele altor grupe.

În general, analiza datelor reprezintă baza evaluării multor aplicații, fie în cadrul etapei de proiectare, fie în operațiile de conducere on-line, în cazul unor procese complexe. În cadrul unor asemenea procese, multitudinea tehnicilor utilizate pentru reprezentarea datelor, pentru măsurarea asemănării dintre elementele reprezentative și grupare poate fi derutantă în ceea ce privește alegerea celor mai potrivite metode de grupare.

Este deosebit de important de a înțelege diferența dintre gruparea spațială care este un proces nesupravegheat și analiza discriminantă care este un proces de clasificare supravegheată [Jain www].

În cadrul clasificării supravegheate, sînt stabilite deja o serie de grupe inițiale, care conțin elemente preclasificate (cu eticheta grupei), problema constă în a

eticheta un nou element întâlnit, dar încă neetichetat. În mod practic, elementele etichetate sînt folosite pentru descrierea grupelor/claselor respective.

În cazul grupării spațiale, plecînd de la elemente inițial neetichetate se ajunge la una sau mai multe grupe semnificative, în funcție de situație.

Gruparea spațială se utilizează pe scara largă în diferite analize, în explorarea datelor, în probleme de luare a deciziilor, situații de învățare asistată, inclusiv recondiționarea documentelor, segmentarea imaginilor, clasificarea modelelor etc. În cele mai multe dintre aceste tipuri de probleme, există puține informații importante disponibile (de exemplu în modelele statistice), iar decidentul, Decision-Making (DM), trebuie să facă adesea numeroase ipoteze privitoare la aceste aspecte. Datorită acestor situații metodologia de grupare spațială poate fi utilizată în special pentru cercetarea legăturilor dintre date, în scopul unor evaluări (preliminare) a structurii acestora, definirea unor elemente/modele reprezentative etc.

Termenul "grupare spațială" (clustering) este folosit în numeroase domenii de cercetare științifică pentru a descrie procesul de grupare a unor modele neetichetate. Aceste domenii folosesc deja diferite terminologii, tehnici și ipoteze, care se referă la etapele procesului de grupare spațială, specifice problemelor abordate.

3.1.1. Etapele procesului de grupare spațială

Etapele unui proces de grupare spațială se referă la rezolvarea următoarelor probleme [Jain *www*]:

1. stabilirea elementelor supuse grupării spațiale;
2. definirea unei măsuri de proximitate în cadrul unei mulțimi;
3. gruparea spațială;
4. extragerea rezultatelor;
5. evaluarea rezultatelor.

Stabilirea elementelor supuse grupării spațiale este o etapă principală care uneori mai include stabilirea numărului de clase/grupe, tipul și scara caracteristicilor/atributelor disponibile, algoritmului de grupare.

Selectarea caracteristicilor este procesul de identificare a celor mai utile și reprezentative attribute/caracteristici utilizate în procesul de grupare spațială. Selectarea acestor caracteristici se referă la modalitatea de a efectua una sau mai multe transformări ale datelor de intrare, în scopul obținerii unor noi caracteristici dominante.

Proximitatea elementelor este măsurată de obicei printr-o funcție de distanță definită de perechi de elemente. Măsurile de asemănare pot fi folosite pentru a caracteriza similitudinea conceptuală dintre două sau mai multe elemente. În literatura de specialitate au fost definite o mulțime de sisteme de măsurare a

distanțelor. Cea mai utilizată este distanța Euclidiană, care poate reflecta similitudinea dintre două elemente, după ce în prealabil s-a definit o metrică pentru fiecare atribut al vectorilor.

Gruparea spațială poate fi realizată în mai multe feluri. Datele de ieșire ale acestora pot fi "hard" (separarea elementelor în grupe clar determinate) sau fuzzy (unde fiecare element are un grad variabil de apartenență la fiecare din grupele rezultate).

Extragerea rezultatelor este procesul de obținere a rezultatelor sub o formă cât mai simplă și reprezentativă. În acest caz, simplitatea este privită fie din perspectiva analizei automate (astfel încât un calculator să poată efectua mai departe procesarea datelor într-un mod eficient) sau din perspectiva umană (astfel încât reprezentarea obținută pentru rezultate să fie mai ușor de înțeles de către om). În cadrul grupării spațiale, extragerea unor rezultate reprezintă, de fapt, o descriere concisă a fiecărei grupe obținute, de obicei prezentate sub forma unor elemente reprezentative.

În principiu toți algoritmi de grupare spațială ar trebui să ne conducă la obținerea unor grupe/clase pentru orice mulțime de date de intrare. Dacă în urma procesului de grupare, utilizând un anumit algoritm, nu se obține gruparea elementelor, atunci poate fi aplicat un alt algoritm care poate furniza rezultate mai bune decât cel utilizat anterior. Astfel, evaluarea rezultatelor unui proces de grupare spațială are mai multe aspecte.

Analiza validității grupelor face o evaluare a rezultatelor procesului de grupare spațială și utilizează, de obicei, un criteriu de optimizare. Această analiză este obiectivă și se efectuează pentru a se determina dacă rezultatele grupării spațiale sînt corecte. O grupă este validată dacă nu a rezultat accidental sau dintr-un capriciu al algoritmului folosit.

3.1.2. Dificultățile utilizatorului și rolul expertizei

Numărul mare de algoritmi de grupare spațială existenți în literatura de specialitate ridică o prima întrebare: cum poate fi stabilit cel mai adecvat algoritm pentru o anumită problemă ce trebuie rezolvată? Criteriile de alegere ale acestuia se bazează pe [Jain www]:

1. modul de formare a grupelor;
2. structura mulțimii de date;
3. sensibilitatea tehnicilor de grupare la modificări ce pot afecta structura mulțimii de date.

Pînă în momentul de față nu există o analiză critică a algoritmilor de grupare spațială care să poată răspunde unor întrebări importante precum:

- cum trebuie normalizate datele?
- ce măsură a similitudinii este adecvată unei situații date?
- cum pot fi folosite cunoștințele din domeniu la rezolvarea unei anume probleme de grupare spațială ?
- cum poate fi grupat spațial un set foarte mare de date, de ordinul a unui milion, de exemplu, în mod eficient?

De asemenea nu există o tehnică de grupare universal aplicabilă la determinarea varietăților de structuri prezente în spațiile multidimensionale. Este evident că oamenii pot asimila ușor rezultatele grupării spațiale bidimensionale, dar majoritatea problemelor reale implică gruparea spațială multidimensională, ale căror rezultate nu pot fi interpretate intuitiv de mintea umană.

3.1.3. Metode de grupare spațială

În cele ce urmează vom defini unii termeni și vom explica unele notații care vor fi utilizate în continuare [Jain www].

Elementul (vectorul) x este un obiect singular folosit în procesul de grupare spațială. El este, de obicei, un vector n -dimensional: $x = [x_1 \ x_2 \ \dots \ x_n]_t$ unde n este dimensiunea modelului sau spațiul modelului. Componentele scalare ale vectorului x , notate x_i , se numesc **caracteristicile** (sau **atributele**) vectorului x . Aceste atribute sînt stabilite de către analist, care stabilește, de asemenea, metrica atributelor respective.

Tehnicile de grupare spațială fuzzy asociază fiecărui vector de intrare x_i un anumit grad de apartenență f_{ij} la fiecare dintre grupele/clasele obținute în urma procesului de grupare spațială.

Distanța dintre vectori constituie o metrică în spațiul atributelor vectorilor de intrare, utilizată la stabilirea similitudinii dintre aceștia.

Există două tipuri principale de grupare spațială: gruparea spațială ierarhică și gruparea spațială K-medii, ambele fiind descrise succint în cele ce urmează.

3.1.3.1. Gruparea spațială ierarhică

Gruparea spațială ierarhică poate fi subîmpărțită, după sensul de desfășurare, în procedee de aglomerare și procedee de divizare. În cazul procedeeleor de aglomerare, de exemplu, se pleacă de la cele n grupe, fiecare conținînd un singur element/obiect, și prin fuziuni succesive se ajunge la o singură grupă, conținînd toate elementele/obiectele. În cazul procedeeleor de divizare, sensul de desfășurare este invers, adică plecînd de la o singură grupă ce conține toate elementele/obiectele, se ajunge la n grupe, fiecare conținînd un singur element/obiect. Tehnicile de

aglomerare sînt, în mod obișnuit, mult mai utilizate. Gruparea ierarhică poate fi reprezentată printr-o diagramă bidimensională denumită dendogramă, care ilustrează fuziunea sau împărțirea făcută la fiecare stadiu succesiv al analizei. Gruparea spațială ierarhică este adecvată pentru tabele mici, pînă la cîteva sute de linii. Se poate alege numărul dorit de grupe/clase după ce este construit arborele corespunzător. Un exemplu de o astfel de dendogramă este dat Fig. 3.1 [Clustering www/2]




Fig. 3.1. Exemplu de dendogramă

Procedee de aglomerare

Așa cum am arătat mai sus, în gruparea spațială ierarhică, un procedeu de aglomerare parcurge o serie de fuziuni/cuplări ale grupelor/claselor, $P_n, P_{n-1}, \dots, P_1$. Prima, P_n , constă din n "grupe" cu un singur element/obiect, ultima P_1 , constă dintr-o singură grupă conținînd toate cele n elemente/obiecte. La fiecare etapă metoda cuplează două grupe apropiate (la primul nivel, desigur, aceasta înseamnă să cuplăm două elemente/obiecte care sînt apropiate unul de altul (ca distanță), întrucît la stadiul inițial fiecare grupă are un obiect).

Diferența dintre metode apare în modul de definire a distanței dintre grupe. Cîteva procedee de aglomerare vor fi prezentate detaliat în continuare.

a. Gruparea spațială pe baza distanței minime (metoda minimului)

Unul din cele mai simple procedee de aglomerare în gruparea spațială ierarhică este cel bazat pe distanța minimă, cunoscut de asemenea ca și tehnica celui mai apropiat vecin. În acest caz distanța dintre grupe este definită ca distanța dintre cele mai apropiate elemente:

$$D(r,s) = \text{Min}\{d(i,j)\} \quad (3.1)$$

unde elementul i este din grupa r , iar elementul j este din grupa s

Aici este calculată distanța dintre fiecare pereche posibilă de elemente (i,j) , unde elementul i este din grupa r și elementul j este din grupa s . Valoarea minimă a acestei distanțe se consideră a fi distanța dintre grupele r și s . Cu alte cuvinte distanța dintre două grupe este dată de valoarea celei mai scurte legături dintre grupele respective. La fiecare stadiu din gruparea spațială ierarhică, grupele r și s , pentru care $D(r,s)$ este minimă sînt cuplate. Această măsură a distanțelor dintre grupe/clase este arătată în Fig. 3.2.




Fig. 3.2. Distanța minimă dintre două grupe

b. Gruparea spațială pe baza distanței maxime (metoda maximului)

Metoda de grupare spațială pe baza distanței maxime, numită metoda celui mai îndepărtat vecin este opusă celei precedente.

În metoda de grupare spațială pe baza distanței maxime, distanța $D(r,s)$ se calculează:

$$D(r,s) = \text{Max} \{d(i,j)\} \quad (3.2)$$

unde elementul i este din grupa r , iar elementul j este din grupa s .

În acest caz distanța dintre două grupe este dată de valoarea celei mai lungi legături dintre grupe, Fig. 3.3. La fiecare etapă a grupării ierarhice spațiale, grupele r și s , pentru care $D(r,s)$ este maximă, sînt cuplate.




Fig. 3.3. Distanța maximă dintre două grupe

c. Gruparea spațială pe baza distanței medii

Aici distanța dintre două grupe este definită ca media distanțelor dintre toate perechile de elemente/obiecte, unde fiecare pereche conține câte un obiect din fiecare grupă.

În această metodă distanța $D(r,s)$ se calculează cu relația:

$$D(r,s) = T_{rs} / (N_r \cdot N_s) \quad (3.3)$$

unde:

T_{rs} - suma tuturor distanțelor posibile dintre elementele grupei r și elementele grupei s ;

N_r, N_s - dimensiunile grupei r , respectiv s .

La fiecare etapă a grupării spațiale ierarhice, grupele r și s pentru care $D(r,s)$ este minimă, sînt cuplate. Fig. 3.4 ilustrează modul de definire a distanței medii.




Fig. 3.4. Definirea distanței medii dintre două grupe

d. Metoda centrului de greutate

În metoda centrului de greutate, distanța dintre două grupe este definită ca distanța pătratică euclidiană dintre centrele lor de greutate.

$$D_{KL} = \|\bar{X}_K - \bar{X}_L\|^2 \quad (3.4)$$

Această metodă este mult mai robustă, prin abaterea mare de la medie, decât alte metode ierarhice, dar în alte situații poate să nu dea rezultate bune, precum metoda Ward sau metoda distanței medii.

e. Metoda de clusterizare ierarhică a lui Ward

Ward propune un procedeu de grupare spațială căutînd să formeze partițiile $P_n, P_{n-1}, \dots, P_1$ într-o manieră care să minimizeze pierderile de informații asociate fiecărei grupări și să măsoare aceste pierderi într-o formă ușor de interpretat. La fiecare pas din analiză sînt combinate două grupe a căror fuziune conduce la rezultate minime în creșterea "informației pierdute". Informația pierdută este definită de Ward în condițiile criteriului suma patratrică a erorii (SPE).

Argumentarea propusă de Ward poate fi ilustrată mult mai simplu considerînd date unidimensionale. Să presupunem pentru exemplu, 10 elemente cu o singură caracteristică (6, 5, 6, 2, 2, 2, 2, 0, 0, 0). Pierdere de informație care va rezulta din gruparea celor 10 elemente într-o singură grupă, cu o medie de 2,5, este reprezentată de SPE, dată de :

$$SPE_{un\ grup} = (2 - 2,5)^2 + (6 - 2,5)^2 + + (0 - 2,5)^2 = 50,5$$

Pe de altă parte, dacă cele 10 elemente sînt grupate după caracteristicile lor, în patru grupe:

$$\{0,0,0\}, \{2,2,2,2\}, \{5\}, \{6,6\}$$

SPE poate fi evaluată ca suma pătratică a patru erori separate:

$$SPE_{un\ grup} = SPE_{grup1} + SPE_{grup2} + SPE_{grup3} + SPE_{grup4} = 0$$

Deci prin dispunerea celor 10 elemente în 4 grupe, gruparea se face fără pierderi de informație.

3.1.4.2. Gruparea spațială K-medii

K-medii este unul din cei mai simplii algoritmi de învățare nesupravegheată care rezolvă bine cunoscuta problemă de grupare spațială. Procedeu urmează o cale simplă și ușoară pentru a clasifica setul datelor de intrare într-un număr de K grupe (K fixat a priori). Ideea de bază este a defini K centre de greutate, unul pentru fiecare grupă. Aceste centre de greutate trebuie fixate rațional, deoarece locații diferite conduc la rezultate diferite. Alegerea cea mai bună este să le fixăm cît este posibil mai depărtate unele de altele. Următorul pas este să luăm fiecare element al setului datelor de intrare și să-l asociem celui mai apropiat centru de greutate. Prima etapă a grupării se termină cînd nu mai există elemente negrupate. În acest moment trebuie să recalculăm K noi centre ale grupelor rezultate din pasul anterior. Procedeu continuă pînă ce pozițiile noilor centre nu se mai modifica semnificativ.

Scopul acestui algoritm este minimizarea unei funcții obiectiv, în acest caz o funcție eroare pătratică. Funcția obiectiv este:

$$J = \sum_{j=1}^k \sum_{i=1}^n \|x_i^{(j)} - c_j\|^2 \quad (3.5)$$

unde $\|x_i^{(j)} - c_j\|^2$ este distanța măsurată între punctul $x_i^{(j)}$ și centrul grupei c_j .

Gruparea spațială K-medii este convenabilă pentru tabele mari de sute de mii de linii.

3.2. Estimarea pierderilor de putere/energie în rețelele de distribuție

3.2.1. Aspecte generale privind pierderile de putere/energie

În planificarea și exploatarea rețelelor electrice de distribuție, pierderile de putere și energie reprezintă un indicator care reflectă condițiile de funcționare, indicator deosebit de important pentru eficiența economică a procesului de distribuție a energiei electrice.

Pentru calculele și analizele tehnico-economice ale pierderilor de putere și energie se consumă o cantitate foarte mare de muncă având în vedere, mai ales, volumul enorm de informații necesare. Metodele și algoritmi pentru determinarea pierderilor de putere și energie se bazează pe calculul regimurilor rețelelor respective. Calculele se fac în condițiile cunoașterii cât mai exacte a datelor de intrare: caracteristicile primare ale fiderilor de MT (tipul, secțiunea și lungimea corespunzătoare fiecărui tronson al fiderilor, numărul posturilor de transformare alimentate, numărul și puterea nominală a transformatoarelor amplasate în aceste posturi) și nivelul de încărcare al acestora.

Metodele folosite pînă în prezent au urmărit, în principal, creșterea preciziei în evaluarea pierderilor. Totuși, o precizie bună și o viteză mare de calcul sînt două cerințe greu de satisfăcut simultan, avînd în vedere că exactitatea rezultatelor impune o modelare mai detaliată a procesului și creșterea numărului parametrilor considerați ca date de intrare.

Intuiția, experiența și descrierea lingvistică sînt folosite din ce în ce mai mult de ingineri în exploatarea și planificarea rețelelor electrice. Termenii lingvistici precum **Scurt** sau **Lung** sînt folosiți pentru a descrie lungimea, iar termenii precum **Mic** sau **Mare**, pentru a indica puterea instalată (suma puterilor nominale ale transformatoarelor amplasate în posturile de transformare alimentate de fider). În asemenea probleme, lungimea fiderilor și puterea instalată, alături de nivelul de încărcare reprezintă factori importanți, pentru mulți decidenți, în estimarea pierderilor de putere din rețelele electrice de distribuție.

În ceea ce privește gradul de încărcare al transformatoarelor, exceptînd măsurătorile obișnuite din stațiile de transformare, există puține informații ce privesc starea acestora. Deoarece nu este posibil de măsurat sarcina în fiecare nod de pe fideri, fiderii și sarcinile nu sînt în mod obișnuit monitorizate. Ca rezultat, există în orice moment un mare grad de incertitudine asupra sarcinii din noduri și, în consecință, asupra nivelului de încărcare al rețelei, nivelului de tensiune din noduri și al pierderilor de putere. Efectele incertitudinii sarcinii din noduri se vor propaga în rezultatele calculelor de regim permanent, afectînd estimarea stării și soluțiile optime ale diferitelor probleme ce privesc exploatarea și planificarea rețelelor de distribuție [Alexandrescu 01], [Grigoraș 04/1].

Intrucât problema fuzzificării sarcinilor din nodurile rețelelor electrice, în general, și a încărcării transformatoarelor în particular, este o chestiune foarte importantă, în acest capitol se prezintă ca exemplu o metodă de fuzzificare a încărcării transformatoarelor care dă rezultate bune în analiza regimurilor rețelelor de distribuție.

Trebuie subliniat că, deși alegerea funcțiilor de apartenență este subiectivă, datorită aplicării unor reguli fuzzy, alese cu grijă, rezultatele obținute pot fi destul de bune.

Pe baza unui set de reguli fuzzy s-a construit un tabel de decizie numit Fuzzy Associate Memory (FAM), cu ajutorul căruia pot fi estimate cu o precizie mai bună pierderile de putere pe unul sau mai mulți fideri, în funcție de variabilele fuzzy de intrare (lungimea fiderilor, puterea instalată și gradul de încărcare al transformatoarelor).

3.2.2. Algoritmul de grupare a fiderilor de MT

În funcție de caracteristicile primare, lungimea totală a fiderilor de MT și puterea instalată a transformatoarelor, fiderii sînt împărțiți în grupe coerente și reprezentative pentru rețelele analizate [Khodr 02].

Informațiile privind caracteristicile primare ale fiderilor au fost actualizate și pregătite pentru procesul de grupare, incluzînd selectarea variabilelor pentru un număr total de 86 de fideri de distribuție ce aparțin unor sucursale de distribuție a energiei electrice din Moldova. Acești fideri fac parte din rețele de distribuție urbană, de 20 kV, ce alimentează consumatori, preponderent, rezidențiali.

Variabilele primare ce caracterizează fiderii de MT sînt următoarele: tipul, secțiunea și lungimea cablului corespunzător fiecărui tronson al fiderilor, numărul posturilor de transformare alimentate, numărul și puterea nominală a transformatoarelor amplasate în aceste posturi. Considerînd în acest caz doar două din caracteristicile primare (lungime totală și putere instalată), fiderii sînt împărțiți în grupe utilizînd o metodă statistică de grupare spațială (hierarchic clustering method) [Grigoraș 04/3].

Prin putere instalată se înțelege suma puterilor (aparente) nominale ale transformatoarelor amplasate, în cazul de față, în posturile de transformare alimentate de fider:

$$S_i^f = \sum_{j=1}^{N_{PT}} S_{ij}^f; \quad f = 1, \dots, N_f \quad (3.6)$$

unde:

S_i^f – puterea instalată a fiderului f ;

S_{nj}^f – puterea nominală a transformatorului din postul j, alimentat de fiderul f;

N_{PT} – numărul total de posturi de transformare alimentate de fiderul f;

N_f – numărul total de fideri din baza de date (în cazul de față $N_f = 86$).

Astfel, au fost determinate 7 grupe de fideri prin aplicarea metodei ierarhizată de grupare spațială (G_1 (21 elemente), G_2 (17 elemente), G_3 (16 elemente), G_4 (8 elemente), G_5 (7 elemente), G_6 (6 elemente) și G_7 (11 elemente)). Aceste grupe sînt prezentate în Fig. 3.5.




Fig. 3.5. Gruparea fiderilor în funcție de lungime și puterea instalată

Dacă numărul de fideri din baza de date crește, se pot obține grupe mult mai reprezentative. Valorile variabilelor m_L^k și $m_{S_i}^k$ pentru elementul (fiderul) mediu al grupei k, se obține calculînd media variabilelor L_f^k și S_{if}^k :

$$m_L^k = \frac{\sum_{f=1}^{N_f^k} L_f^k}{N_f^k}; \quad m_{S_i}^k = \frac{\sum_{f=1}^{N_f^k} S_{if}^k}{N_f^k}; \quad k = 1, \dots, N_G \quad (3.7)$$

unde:

L_f^k - lungimea fiderului f din grupa k;

S_{if}^k - puterea instalată pe fiderul f din grupa k ;

N_G - numărul total de grupe de fideri (în cazul de față $N_G = 7$);

N_f^k - numărul total de fideri din fiecare grupă.

Cunoscând valorile m_L^k și $m_{S_i}^k$, $k = 1, \dots, 7$, ale elementelor medii din grupele stabilite anterior, în continuare sînt determinate abaterile standard ale lungimii, σ_L^k , respectiv ale puterii instalate, $\sigma_{S_i}^k$, din grupele analizate cu relațiile:

$$\sigma_L^k = \sqrt{\frac{\sum_{f=1}^{N_f^k} (L_f^k - m_L^k)^2}{N_f^k}}; \quad \sigma_{S_i}^k = \sqrt{\frac{\sum_{f=1}^{N_f^k} (S_{if}^k - m_{S_i}^k)^2}{N_f^k}}; \quad k = 1, \dots, N_G \quad (3.8)$$

În Tabelul 3.1 sînt prezentate valorile parametrilor m_L^k , $m_{S_i}^k$, σ_L^k și $\sigma_{S_i}^k$ pentru cele 7 grupe de fideri.

Tabelul 3.1. Valorile m și σ corespunzătoare lungimii și puterii instalate

Grupa	Lungimea [km]		Puterea instalată [kVA]	
	m_L	σ_L	m_{S_i}	σ_{S_i}
G1	1,49	0,47	2132,00	525,93
G2	3,26	0,39	2552,00	524,56
G3	2,31	0,55	4013,00	633,31
G4	4,23	0,32	3840,00	490,19
G5	5,50	0,35	4301,43	616,70
G6	3,75	0,67	5871,00	373,71
G7	5,67	0,45	6088,18	617,70

Dacă pentru lungime (L) definim următoarele trei categorii lingvistice: **Scurtă** (**Low** - **LL**), **Medie** (**Medium** - **ML**) și **Lungă** (**High** - **HL**), iar pentru puterea instalată (S_i), **Mică** (**Low** - **LS**), **Medie** (**Medium** - **MS**) și **Mare** (**High** - **HS**), fiecare grupă va fi caracterizată de cîte o categorie lingvistică ce corespunde lungimii, respectiv puterii instalate, Fig. 3.6 (a și b), Tabelul 3.2.

De exemplu, prima grupă se caracterizează printr-o lungime **LL** și o putere instalată **LS**. Examinînd Fig. 3.5 se poate observa că nu toate căsuțele obținute prin împărțirea lungimii, respectiv puterii instalate, în categorii lingvistice, sînt caracterizate de grupe de fideri rezultate din procesul de grupare. Căsuțele ce nu

conțin grupe de fideri aparțin unor cazuri puțin probabile în practică, sau, mai degrabă, nesemnificative din punctul de vedere al studiului de față.




Fig. 3.6. Funcțiile de apartenență pentru lungime (a) și puterea instalată (b)

Tabelul 3.2. Categoriile lingvistice corespunzătoare lungimii și puterii instalate

Grupa	Categoriile lingvistice	
	Lungime	Putere instalată
G1	LL	LS
G2	ML	LS
G3	LL	MS
G4	ML	MS
G5	HL	MS
G6	ML	HS
G7	HL	HS

3.2.3. Modelarea încărcării rețelelor de distribuție prin tehnici fuzzy

Deoarece nu este posibil de măsurat sarcina în fiecare nod de pe fideri, fiderii și sarcinile nu sînt în mod obișnuit monitorizate. Ca rezultat, există în orice moment un mare grad de incertitudine asupra sarcinii din noduri și, în consecință, și asupra nivelului de încărcare al rețelei, al nivelului de tensiune din noduri și al pierderilor de putere. Efectele incertitudinii sarcinii din noduri se vor propaga în rezultatele calculelor de regim permanent, afectînd estimarea stării și soluțiile optime ale diferitelor probleme ce privesc exploatarea și planificarea rețelelor de distribuție.

Pînă acum cîțiva ani, incertitudinile au fost luate în considerare prin intermediul modelelor probabilistice, uneori fără a avea un suport statistic datorită lipsei informațiilor corespunzătoare. În ultimii ani, incertitudinile privitoare la sarcini au fost modelate apelînd la experiența specialiștilor și la măsurători de sarcină executate și înregistrate, la diferite tipuri de consumatori, lucru care poate conduce la aprecierea sarcinilor pe baza mărimilor fuzzy.

Pentru că în multe situații nu se dispune de date adecvate privind sarcina pentru fiecare nod, în scopul modelării acesteia la barele de JT ale posturilor de transformare se propune utilizarea expresiilor lingvistice a două variabile fuzzy primare: factorul de încărcare kI [%] al transformatoarelor din posturile de transformare ale rețelei de distribuție și factorul de putere $\cos\varphi$, astfel încît reprezentarea fuzzy corespunzătoare puterilor active și reactive rezultă din relațiile [Alexandrescu 01], [Cârțină 03/1]:

$$P = \frac{kI}{100} \cdot S_n \cdot \cos \varphi, \quad Q = P \cdot \tan \varphi \quad (3.9)$$

unde S_n [kVA] reprezintă puterea nominală a transformatoarelor din posturile de transformare.

Variabilelor fuzzy, kI și $\cos\varphi$, le asociem funcții de apartenență trapezoidale. Alegerea numerelor fuzzy adecvate variabilelor kI și $\cos\varphi$ depinde de experiența proiectantului sau a specialiștilor implicați în supravegherea și conducerea rețelei. Pe baza experienței autorilor și cercetării bibliografice în domeniul rețelor de distribuție urbane și rurale, în lucrarea [Alexandrescu 01] se propune alegerea variabilelor fuzzy conform Tabelul 3.3. Se precizează că numerele fuzzy din acest tabel corespund, în principal, consumatorilor rezidențiali. Referitor la datele numerice respective se impune următoarea observație: între numerele fuzzy kI și $\cos\varphi$ se admite o anumită corelație, determinată, de regulă, de condiția variației în același sens a încărcării și a factorului de putere. În cazuri concrete, pentru tipuri particulare de consumatori se pot defini alte reguli.

Determinarea pierderilor de putere s-a făcut pentru cinci grade de încărcare ale fiderilor cu calificativele lingvistice VS, S, M, H și VH folosind modelarea fuzzy a sarcinii, pe baza variabilelor fuzzy kI și $\cos\varphi$:

1. Foarte Mică (Very Small – VS): kI - VS și $\cos\varphi$ - VS;
2. Mică (Small – S): kI - S și $\cos\varphi$ - S;
3. Medie (Medium – M): kI - M și $\cos\varphi$ - M;
4. Mare (High – H): kI - H și $\cos\varphi$ - H;
5. Foarte Mare (Very High – VH): kI - VH și $\cos\varphi$ - VH.

Tabelul 3.3. Gradele de încărcare în funcție de valorile variabilelor kI și $\cos\varphi$

Categoria lingvistică		x		Categoria lingvistică		x	
		$kI(\%)$	$\cos\varphi$			$kI(\%)$	$\cos\varphi$
VS	x_1	10	0,70	M	x_3	31	0,89
	x_2	10	0,70		x_4	33	0,90
	x_3	13	0,74	H	x_1	31	0,89
	x_4	15	0,75		x_2	33	0,90
S	x_1	13	0,74		x_3	39	0,91
	x_2	15	0,75		x_4	41	0,92
	x_3	22	0,82	VH	x_1	39	0,91
	x_4	24	0,83		x_2	41	0,92
M	x_1	22	0,82		x_3	60	0,93
	x_2	24	0,83		x_4	60	0,93

Calcululele de regim permanent vor fi făcute în fiecare din cele patru puncte caracteristice ale trapezelor fuzzy. Pentru fiecare grad de încărcare (GI), s-au calculat pierderile de putere corespunzătoare fiecărui fider din grupele obținute. În Tabelul 3.4 sînt prezentate valorile crisp corespunzătoare pierderilor de putere ale elementelor medii, din fiecare grupă de încadrare.

Tabelul 3.4. Valorile medii [kW] și dispersiile pierderilor de putere [kW] pentru grupelor de fideri, în funcție de gradul de încărcare

Grupa	Grad de încărcare (GI)									
	VS		S		M		H		VH	
	m	σ	m	σ	m	σ	M	σ	m	σ
G1	7,65	1,89	8,45	2,09	9,99	2,53	12,02	3,03	16,92	4,32
G2	9,43	2,13	10,64	2,37	12,58	2,87	15,05	3,47	21,38	4,99
G3	13,91	1,42	15,54	1,65	18,72	2,17	22,55	2,15	32,41	3,18
G4	14,01	2,57	15,60	2,89	18,52	3,37	22,54	4,19	32,58	6,59
G5	15,91	1,96	17,86	2,31	21,30	3,06	26,24	4,04	38,70	6,49
G6	20,81	2,19	23,39	2,62	28,39	3,47	34,89	4,58	50,78	7,36
G7	21,48	2,36	25,10	2,64	31,22	3,40	39,20	4,47	58,75	7,12

Pentru defuzzificare s-a folosit metoda centrului de greutate:

$$CG = \frac{\sum_{i=1}^4 x_i \cdot \mu(x_i)}{\sum_{i=1}^4 \mu(x_i)} \quad (3.10)$$

În Fig. 3.7 este prezentată variația pierderilor medii de putere corespunzătoare fiecărei grupe de fideri în funcție de gradul de încărcare. Pierderile de energie vor fi obținute făcând suma pierderilor de putere pe perioada studiată.




Fig. 3.7. Variația pierderilor de putere în funcție de gradul de încărcare al transformatoarelor

3.2.4. Estimarea pierderilor de putere/energie folosind Logica fuzzy

În cele ce urmează suportul determinării pierderilor de putere îl constituie Logica fuzzy, care include folosirea funcțiilor de apartenență, stabilirea și folosirea unor reguli fuzzy, precum și operațiile de fuzzificare/defuzzificare. Pe baza unui set de reguli fuzzy de tipul:

If L is SL and S_i is LS and GI is VS Then dP is VS

s-a construit un tabel de decizie numit Fuzzy Associate Memory (FAM), Tabelul 3.5, cu ajutorul căruia pot fi determinate pierderile de putere pe un anumit fider. Mărimile de intrare sînt lungimea fiderului, puterea instalată și gradul de încărcare,

iar mărimea de ieșire sînt pierderile de putere. Pentru pierderile de putere s-a avut în vedere o reprezentare prin cinci categorii lingvistice, Fig. 3.8.




Fig. 3.8. Funcțiile de apartenență pentru pierderile de putere dP

Very Small (VS_dP):	4 – 10 kW
Small (S_dP):	10 – 15 kW
Medium (M_dP):	10 – 20 kW
High (H_dP):	20 – 30 kW
Very High (VH_dP) :	30 – 60 kW

Tabelul 3.5. Tabelul de decizie (FAM) pentru estimarea pierderilor de putere

		Lungimea									
		LL			ML			HL			
		VS_dP	S_dP		VS_dP	S_dP	H_dP		M_dP	H_dP	
Gradul de încărcare	VS	VS_dP	S_dP		VS_dP	S_dP	H_dP		M_dP	H_dP	
	S	VS_dP	M_dP		S_dP	M_dP	H_dP		M_dP	H_dP	
	M	VS_dP	M_dP		S_dP	M_dP	H_dP		H_dP	VH_dP	
	H	S_dP	H_dP		M_dP	H_dP	VH_dP		H_dP	VH_dP	
	VH	M_dP	VH_dP		H_dP	VH_dP	VH_dP		VH_dP	VH_dP	
		LS	MS	HS	LS	MS	HS	LS	MS	HS	
Puterea instalată											

Analizând rezultatele obținute se poate observa faptul că Tabelul 3.5 nu este complet. Nu s-au completat acele coloane care aparțin unor cazuri puțin probabile în practică sau, mai degrabă, nesemnificative din punctul de vedere al studiului de față. În Fig. 3.9 sînt reprezentate pierderile de putere calculate cu ajutorul tabelului de decizie, în funcție de lungime și puterea instalată.




Fig. 3.9. Pierderile de putere calculate cu ajutorul tabelului de decizie, în funcție de lungimea fiderului și putere instalată

Pentru exemplificarea folosirii metodei prezentate, se consideră estimarea pierderilor de putere pe un fider caracterizat de următoarele valori: $L = 3,5$ km, $S_f = 3625$ [kVA], $GI = 35$ [%]. Baza de reguli corespunzătoare sistemului fuzzy (35 de reguli fuzzy) este prezentată în Fig. 3.10. Sistemul fuzzy a fost construit în limbajul MatLab, cu ajutorul toolbox-ului Fuzzy Logic. Rezultatul aplicării regulilor fuzzy este un nivel lingvistic mare (H_{dp}) pentru pierderile de putere, valoarea defuzzificată a acestora fiind 25 kW.




Fig. 3.10. Estimarea fuzzy a pierderilor de putere
(cazul $L=3,5$ km, $S_i=3625$ [kVA], $GI=35$ [%])

3.3. Determinarea benzilor optime de reglare a tensiunii în rețelele electrice de transport

3.3.1. Determinarea profilurilor de sarcină în rețelele electrice de 110 kV

În acest paragraf se propune o abordare relativ nouă a determinării profilurilor de sarcină din nodurile rețelelor electrice de 110 kV. O alternativă la determinarea consumului de energie pe baza măsurărilor efectuate în nodurile rețelelor electrice se referă la stabilirea profilului tip de sarcină a fiecărui nod. Fiecărui nod de 110 kV îi este asociat un profil reprezentativ.

Pentru rezolvarea acestei probleme s-au utilizat tehnicile de grupare ierarhică, scopul acestora fiind de aranjare a graficelor zilnice de sarcină ale nodurilor de 110 kV în grupe distincte numite profiluri tip de sarcină. Rezultatele obținute demonstrează capacitatea acestor tehnici de a depăși dificultățile metodelor tradiționale în analiza regimurilor rețelelor electrice de 110 kV.

Cunoscând profilurile de sarcină din nodurile rețelelor electrice, companiile de electricitate pot simplifica algoritmul de estimare a cererii de energie din zonelor pe care aceste rețele le alimentează. Astfel, aceste companii pot dezvolta ulterior strategii de marketing superioare, îmbunătățindu-și eficiența.

Graficul de sarcină al fiecărui nod de 110 kV este construit folosind profilul tip de sarcină zilnic normat și consumul zilnic (lunar, anual, depinde de caz) de energie. Profilul tip de sarcină zilnic normat se caracterizează prin 24 de valori ale sarcinii. Forma graficelor de sarcină este influențată de tipul nodului, al zilei și de anotimpul în care se execută studiul. Intrucât modul de determinare a graficelor tip de sarcină este identic pentru toate tipurile de noduri, el va fi exemplificat în continuare numai pentru regimul de iarnă în ziua în care s-a înregistrat vârful de sarcină în sistemul analizat (16.01.2002), (Electrica Moldova).

Datorită faptului că un număr mare de profiluri de sarcină asociate diferitelor noduri ale rețelei pot crea probleme complicate, acestea pot fi aranjate în grupe coerente, pe baza existenței anumitor similitudini între ele. Pentru fiecare grupă, se determină profilul tip de sarcină. Fiecărui nod de 110 kV îi va fi asociat câte un profil tip de sarcină folosind principiul detaliat în Fig. 3.11 [Gerbec 02].

În acest sens toate măsurătorile efectuate trebuie prelucrate, prin aranjarea și normalizarea acestora, utilizând un factor de normalizare convenabil (puterea medie, puterea de vîrf sau, mai frecvent, consumul de energie din perioada studiată):

$$z_{ij} = x_{ij} / \sum_i x_{ij} \quad (3.11)$$

unde:

z_{ij} – valoarea normalizată;

x_{ij} – valoarea concretă (măsurată);

$\sum_i x_{ij}$ – consumul total de energie din perioada studiată.

Este important de subliniat faptul că, în timp ce gruparea curbelor de sarcină prin comparare vizuală este subiectivă și greu de aplicat, tehnicile de grupare spațială rezolvă această problemă prin compararea profilurilor de sarcină și gruparea progresivă în grupe coerente și reprezentative, astfel încît profilurile din cadrul aceleiași grupe să fie similare [Gerbec www], [Gubina www].




Fig. 3.11. Diagrama de determinare a profilurilor tip de sarcină

Dintre metodele de grupare a fost utilizată metoda distanței medii, care face parte din categoria metodelor de grupare ierarhice. Aceasta a fost aplicată pentru o bază de date corespunzătoare zilei în care s-a înregistrat vârful de sarcină al sistemului analizat (16.01.2002), cuprinzând datele pentru 155 de noduri de 110 kV. În prelucrările statistice au fost luate în considerare numai 137 noduri pentru determinarea graficelor tip de putere activă și 125 noduri pentru determinarea graficelor tip de putere reactivă (restul datelor nu au fost corecte sau aparțineau unor noduri ce alimentau stații CFR).

Graficele de sarcină ale puterilor active și reactive corespunzătoare nodurilor luate în considerare au fost normalizate în raport cu consumul de energie al fiecărui nod de 110 kV din ziua în care s-a înregistrat vârful de sarcină al sistemului (16.01.2002) cu relația:

$$p_i^h = \frac{P_i^h}{E_{P_i}}; \quad q_i^h = \frac{Q_i^h}{E_{Q_i}}; \quad h = 1, \dots, 24; \quad i = 1, \dots, N_R \quad (3.12)$$

unde:

P_i^h , Q_i^h - puterea activă, respectiv reactivă cerută în nodul i la ora h , în [MW], respectiv [MVar];

E_{P_i} , E_{Q_i} – consumurile de energie activă, respectiv reactivă a consumatorului i în ziua de 16.01.02, în [MWh], respectiv [MVarh];

N_R – numărul total de noduri luate în considerare pentru clasificarea după puterea activă, respectiv reactivă.

3.3.2. Algoritmul de grupare a profilurilor de sarcină

În urma procesului de grupare au rezultat două grupe pentru puterea activă (C_{P1} și C_{P2}), Fig. 3.12, și o singură grupă (C_{Q1}) pentru puterea reactivă, Fig. 3.13.

Prima grupă corespunzătoare puterii active, C_{P1} , are în componență 78 de elemente (noduri), a doua grupă, C_{P2} , 17 elemente (noduri), iar grupa corespunzătoare puterii reactive, C_Q , 98 de elemente (noduri). Restul nodurilor, pînă la 137, pentru puterea activă, respectiv 125, pentru puterea reactivă, au rămas neclasificate în urma procesului de grupare.

Dacă ar fi existat o bază de date mai consistentă s-ar fi putut obține mai multe grupe corespunzătoare puterii active și reactive și foarte puține noduri ar fi rămas neclasificate.




Fig. 3.12. Dendrograma pentru gruparea nodurilor după puterea activă




Fig. 3.13. Dendograma pentru gruparea nodurilor după puterea reactivă

Valorile parametrilor orari $m_{C_{Pk}}^h$ și $m_{C_{Qk}}^h$ pentru elementul/reprezentatul mediu al grupelor de mai sus (C_{P1} (78 elemente), C_{P2} (17 elemente) și C_{Q1} (98 elemente)), se obțin calculând media coeficienților p_i^h și q_i^h :

$$m_{C_{Pk}}^h = \frac{\sum_{i=1}^{N_{C_{Pk}}} p_i^h}{N_{C_{Pk}}}; \quad h = 1, \dots, 24; \quad k = 1, \dots, N_{GP} \quad [\text{MW/MWh}] \quad (3.13)$$

$$m_{C_{Qk}}^h = \frac{\sum_{i=1}^{N_{C_{Qk}}} q_i^h}{N_{C_{Qk}}}; \quad h = 1, \dots, 24; \quad k = 1, \dots, N_{GQ} \quad [\text{MVar/MVarh}] \quad (3.14)$$

unde:

N_{GP} , N_{GQ} reprezintă numărul de grupe corespunzătoare puterii active, respectiv reactive;

$N_{C_{Pk}}$, $N_{C_{Qk}}$ - numărul de elemente din fiecare grupă rezultată în urma procesului de clasificare după puterea activă, respectiv reactivă.

Parametrii $m_{C_{Pk}}^h$ și $m_{C_{Qk}}^h$ sînt coeficienții de transformare a energiei consumate de reprezentatul mediu al grupei k , în putere medie activă și reactivă cerută de acesta.

Reprezentarea grafică a parametrilor $m_{C_{Pk}}^h$ și $m_{C_{Qk}}^h$ din Tabelul 3.6 ne conduce la graficele tip de sarcină corespunzătoare puterii active și reactive din Fig. 3.14, 3.15 și 3.16, corespunzătoare nodurilor de 110 kV, iarna. Graficele reprezintă variația orară a parametrilor $m_{C_{Pk}}^h$ și $m_{C_{Qk}}^h$, cu ajutorul cărora se pot transforma consumurile de energie activă și reactivă în putere activă și reactivă medie.


Abaterile standard $\sigma_{C_{Pk}}^h$ și $\sigma_{C_{Qk}}^h$ se calculează cu relațiile:



$$\sigma_{C_{Pk}}^h = \sqrt{\frac{\sum_{i=1}^{N_{C_{Pk}}} (p_i^h - m_{C_{Pk}}^h)^2}{N_{C_{Pk}}}}; h = 1, \dots, 24; k = 1, \dots, N_{GP} \text{ [MW/MWh]} \quad (3.15)$$

$$\sigma_{C_{Qk}}^h = \sqrt{\frac{\sum_{i=1}^{N_{C_{Qk}}} (q_i^h - m_{C_{Qk}}^h)^2}{N_{C_{Qk}}}}; h = 1, \dots, 24; k = 1, \dots, N_{Gq} \text{ [MVar/MVarh]} \quad (3.16)$$

Tabelul 3.6. Valorile medii și dispersiile corespunzătoare grupelor C_{P1} , C_{P2} și C_{Q1}

Grupa Ora	P				Q	
	C_{P1}		C_{P2}		C_{Q1}	
	m [MW/ MWh]	σ	m [MW/ MWh]	σ	M [MVAh/ MVAh]	σ
1	0,0316	0,0043	0,0334	0,0054	0,0304	0,0093
2	0,0311	0,0044	0,0337	0,0045	0,0292	0,0082
3	0,0313	0,0041	0,0336	0,0050	0,0293	0,0079
4	0,0314	0,0040	0,0328	0,0055	0,0289	0,0080
5	0,0327	0,0040	0,0350	0,0040	0,0308	0,0087
6	0,0360	0,0043	0,0359	0,0055	0,0325	0,0097
7	0,0416	0,0040	0,0430	0,0045	0,0417	0,0111
8	0,0460	0,0044	0,0510	0,0046	0,0439	0,0127
9	0,0460	0,0040	0,0532	0,0064	0,0483	0,0144
10	0,0447	0,0041	0,0545	0,0070	0,0501	0,0173
11	0,0438	0,0041	0,0542	0,0061	0,0511	0,0124
12	0,0436	0,0041	0,0515	0,0052	0,0515	0,0137
13	0,0427	0,0044	0,0507	0,0056	0,0496	0,0113
14	0,0426	0,0038	0,0504	0,0049	0,0507	0,0116
15	0,0428	0,0036	0,0496	0,0061	0,0491	0,0107
16	0,0430	0,0035	0,0402	0,0064	0,0453	0,0099
17	0,0464	0,0046	0,0404	0,0055	0,0459	0,0110
18	0,0514	0,0053	0,0418	0,0069	0,0473	0,0119
19	0,0530	0,0058	0,0395	0,0049	0,0479	0,0115
20	0,0518	0,0054	0,0386	0,0034	0,0450	0,0112
21	0,0486	0,0047	0,0367	0,0030	0,0419	0,0112
22	0,0435	0,0045	0,0350	0,0032	0,0394	0,0085
23	0,0386	0,0042	0,0328	0,0052	0,0361	0,0081
24	0,0358	0,0051	0,0324	0,0058	0,0338	0,0085

Fig. 3.14. Graficul tip de sarcină pentru grupa C_{P1}

Fig. 3.15. Graficul tip de sarcină pentru grupa C_{P2} Fig. 3.16. Graficul tip de sarcină pentru grupa C_Q

3.3.3. Aspecte generale privind reglajul tensiune-putere reactivă

Reglajul tensiune-putere reactivă, UQ , în rețelele electrice este o problemă complexă și care cere un mare efort și timp din partea inginerilor din sistem, care trebuie să definească strategiile corespunzătoare și să realizeze implementarea algoritmilor de conducere.

Orice modificare în topologia rețelei sau în cererea de putere poate produce o creștere sau o micșorare a tensiunii în nodurile rețelei. Operatorii din centrele de dispecer trebuie să asigure calitatea și securitatea alimentării, prin menținerea tensiunii nodurilor între limitele prescrise.

Asigurarea unui plan optimal de tensiune în rețelele electrice de transport și distribuție reprezintă o problemă de calitate, dar și una de securitate în funcționare. Mai mult, tensiunea nodurilor este considerată unul dintre cei mai importanți indicatori de performanță pentru calitate și siguranță.

Reglajul tensiunii se face prin controlul producției, consumului și circulației de putere reactivă la diferite nivele ale sistemului electroenergetic (transport, distribuție). Problema este pusă în mod diferit la nivelul de transport și la nivelul de distribuție a energiei electrice.

În primul caz, rețeaua electrică beneficiază de posibilitățile de reglare oferite de generatoare. Rețeaua de înaltă tensiune, specifică sistemelor de transport, este puternic interconectată, iar consumatorii nu sînt conectați direct la aceasta. În plus, majoritatea consumatorilor alimentați de la această rețea dispun de sisteme proprii de reglaj tensiune-putere reactivă. Pentru rețeaua de transport, obiectivul principal este menținerea unui nivel de tensiune cît mai constant, dacă se poate optimal, și limitarea pierderilor de putere în rețea. De asemenea, trebuie avută în vedere și o rezervă de putere reactivă, necesară pentru menținerea stabilității în condițiile unor perturbații.

În cazul rețelei de distribuție, obiectivul îl constituie minimizarea pierderilor de putere/energie și menținerea tensiunii între limitele admisibile.

Pentru soluționarea reglajului UQ există abordări specifice fiecărei companii de transport, cea mai mare parte adoptînd o structură ierarhică, adică descompunerea reglajului UQ în trei nivele: **primar**, **secundar** și **terțiar**.

Reglajul primar vizează acționarea echipamentelor locale de reglare a tensiunii și urmărește aducerea tensiunii nodului respectiv la valoarea de consemn.

Reglajul secundar realizează controlul tensiunii într-o anumită zonă, elaborînd consemnul pentru comanda dispozitivelor de reglaj UQ din nodurile reglante.

Reglajul terțiar realizează planul optimal de tensiune pe ansamblul rețelei, pe termen scurt (24h) și foarte scurt (15 – 30 minute). În cadrul reglajului terțiar sînt calculate și reactualizate, on-line, tensiunile optime ale nodurilor reprezentative, plecînd de la estimările pe termen scurt ale cererii de putere și ale estimatorilor de stare.

Estimarea puterilor cerute pe termen scurt (24h) permite să se determine planul optimal de tensiune, definit prin minimizarea pierderilor de putere active, pentru intervalele de timp cele mai reprezentative ale curbei zilnice se sarcină. Realizarea acestui plan optimal de tensiune este condiționată de exactitatea estimării de putere.

În cazul unei estimări slabe, este necesară o estimare de putere pe termen foarte scurt (15 – 30 minute), plecînd de la estimatorii de stare curenți, urmată de o optimizare corespunzătoare.

Scopul reglajului tensiune/putere reactivă este determinarea unui profil optimal de tensiune, pentru intervalele de timp reprezentative din graficul zilnic de sarcină, acest profil fiind corespunzător pierderilor de putere minime.

Problema optimizării controlului UQ este una de optimizare neliniară. Se pleacă de la ipoteza că obiectivul principal al rețelelor de transport este un nivel de tensiune cât mai constant, dacă se poate în interiorul unei benzi optimale, și limitarea pierderilor de putere. Dacă nivelul optimal de tensiune se definește cel corespunzând minimului pierderilor de putere în rețea, vom căuta reglajul care conduce la acest minim. Variabilele de control sînt tensiunile nodurilor reglante și poziția ploturilor auto(transformatoarelor).

Pentru determinarea unei poziții corespunzătoare a ploturilor transformatoarelor, astfel încît acestea să se găsească într-un interval (bandă) optim de reglare, este necesar efectuarea unor studii ample ce privesc optimizarea regimurilor de funcționare pentru diferite profiluri ale sarcinii din nodurile sistemului. Această abordare (constînd în studii ample) este însă inefficientă din punct de vedere al conducerii în timp real a proceselor din sistemul electroenergetic. De aceea, în cele ce urmează se va prezenta o metodă de determinare a priori a unor benzi optime de reglare a ploturilor autotransformatoarelor și transformatoarelor cu reglaj sub sarcină amplasate în stațiile de transformare, pornind de la ideea că fiecărui (auto)transformator îi corespunde o bandă specifică de reglaj.

3.3.4. Modelul matematic de optimizare

Optimizarea reglajului UQ în rețelele electrice constă în minimizarea pierderilor de putere funcție de variabilele $[U]$, $[\theta]$ și $[w]$, în condițiile respectării unor restricții.

O asemenea problemă se poate pune sub forma unui model de tipul [Cârțină 03/1]:

$$F([\theta],[U],[tc]) = \Delta P([\theta],[U],[tc]) + \sum_{i \in q} QGC_i(Q_i) + \frac{1}{T} \sum_{i,j \in r} TSC_{ij \in r}(\Delta tc_{ij}) = \min ! \quad (3.17)$$

$$\begin{aligned} P_i([\theta],[U],[tc]) - P_{G_i} + P_{L_i} &= 0, & i \in n \setminus e, \\ Q_i([\theta],[U],[tc]) - Q_{G_i} + Q_{L_i} &= 0, & i \in C, \\ U_{i \min} \leq U_i \leq U_{i \max}, & & i \in n, \\ Q_{i \min} \leq Q_i([\theta],[U],[tc]) \leq Q_{i \max}, & & i \in q, \end{aligned} \quad (3.18)$$

$$\begin{aligned}
 tc_{ij \min} \leq tc_{ij} \leq tc_{ij \max}, & \quad ij \in r, \\
 0 \leq I_{ij}^2([\theta], [U], [tc]) \leq I_{ij \max}^2, & \quad ij \in b,
 \end{aligned}$$

unde:

$F([\theta], [U], [tc])$ – funcția obiectiv a modelului de optimizare, [MW];
 $\Delta P([\theta], [U], [tc])$ – pierderile de putere activă, [MW];
 $QGC_i (Q_i)$ – costul producerii puterii reactive QP_i în sursa din nodul i , [MW/MVAr];
 $CPOLT_{ij}$ – costul schimbării ploturilor în transformatorul (i, j) , [MW];
 $[U]$ - vectorul tensiunilor nodale, [kV], dimensiune n ;
 $[\theta]$ - vectorul argumentelor tensiunilor nodale, în raport cu tensiunea nodului de echilibru, dimensiunea $(n-1)$;
 $[w]$ - vectorul ploaturilor transformatoarelor, dimensiunea R ;
 e – nodul de echilibru al rețelei;
 T – perioada de studiu pentru care se realizează optimizarea, [h];
 c, q, r – mulțimea nodurilor consumatoare, cu reglaj de putere reactivă, respectiv cu transformatoare cu reglaj al ploturilor.
 Variabilele modelului de optimizare sînt:

$$[Z] = [[X][Y]]_t; \quad [X] = [[U_q][w]]_t; \quad [Y] = [[\theta][U_e]]_t, \quad (3.19)$$

unde:

$[X]$ - variabilele de reglaj (independente);
 $[Y]$ - variabilele de stare.

Pentru rezolvarea modelului de optimizare de mai sus se poate aplica cu rezultate foarte bune metoda programării pătratice successive [Cârțină 03/1].

3.3.5. Rezultate numerice

Pentru a examina influența sarcinii rețelei asupra instalațiilor de reglaj UQ, de o manieră adecvată, se folosește un model fuzzy pentru puterea activă și reactivă, bazat pe funcții de apartenență de formă trapezoidală ca în Fig. 3.17, avînd parametrii din Tabelul 3.7.




Fig. 3.17. Modelul trapezoidal fuzzy pentru P și Q

Tabelul 3.7. Valorile “breaking points” pentru coeficienții orari din Tabelul 3.6, pentru grupele C_{P1} , C_{P2} și C_{Q1}

Grupa Breaking points	C_{P1}	C_{P2}	C_{Q1}
x_1	$m_{C_{P1}}^h - 1.1 \sigma_{C_{P1}}^h$	$m_{C_{P2}}^h - 1.12 \sigma_{C_{P2}}^h$	$m_{C_{Q1}}^h - 1.28 \sigma_{C_{Q1}}^h$
x_2	$m_{C_{P1}}^h - \sigma_{C_{P1}}^h$	$m_{C_{P2}}^h - \sigma_{C_{P2}}^h$	$m_{C_{Q1}}^h - \sigma_{C_{Q1}}^h$
x_3	$m_{C_{P1}}^h + \sigma_{C_{P1}}^h$	$m_{C_{P2}}^h + \sigma_{C_{P2}}^h$	$m_{C_{Q1}}^h + \sigma_{C_{Q1}}^h$
x_4	$m_{C_{P1}}^h + 1.1 \sigma_{C_{P1}}^h$	$m_{C_{P2}}^h + 1.12 \sigma_{C_{P2}}^h$	$m_{C_{Q1}}^h + .28 \sigma_{C_{Q1}}^h$




Fig. 3.18. Schema rețelei test (220/110 kV)

Dacă se consideră cazul unei rețele de 220/110 kV cu 10 noduri și 12 laturi, a cărei schemă monofilară este prezentată în Fig. 3.18. Rezultatele procesului de optimizare, folosind metoda programării pătratice succesive, sînt consemnate în Tabelul 3.8, Fig. 3.19 – 3.21.

Tabelul 3.8. Valorile finale ale funcției obiectiv și variabilele de control fuzzy

Funcția obiectiv						Variabilele de control fuzzy														
						T ₁₋₂					T ₅₋₆					T ₈₋₉				
x ₁	x ₂	x ₃	x ₄	crisp	real	x ₁	x ₂	x ₃	x ₄	real	x ₁	x ₂	x ₃	x ₄	real	x ₁	x ₂	x ₃	x ₄	real
0,54	0,55	0,85	0,88	0,71	0,79	8	8	11	11	10	7	7	10	10	9	2	2	4	4	4
0,54	0,55	0,83	0,85	0,69	0,79	8	8	10	11	10	7	7	10	10	9	2	2	4	4	4
0,54	0,56	0,82	0,85	0,69	0,80	8	8	10	11	10	7	7	9	10	9	2	2	4	4	4
0,54	0,55	0,82	0,85	0,69	0,79	8	8	10	11	10	7	7	9	10	9	2	2	4	4	4
0,58	0,59	0,87	0,90	0,74	0,82	8	9	11	11	10	7	8	10	10	9	2	2	4	4	4
0,61	0,64	0,98	1,01	0,81	0,87	8	9	11	11	10	7	8	10	10	9	2	3	4	4	4
0,80	0,83	1,25	1,30	1,05	0,98	10	10	14	15	11	9	9	13	14	10	3	3	5	5	4
0,93	0,96	1,47	1,53	1,22	1,23	10	10	15	15	12	9	9	14	14	9	3	3	6	7	5
0,95	1,00	1,57	1,64	1,29	1,36	10	10	15	15	13	9	10	14	15	13	3	4	6	7	5
0,91	0,96	1,61	1,71	1,30	1,30	10	10	15	15	13	9	10	15	15	12	3	4	7	7	5
0,94	0,98	1,52	1,59	1,26	1,33	10	11	15	15	14	10	10	14	15	14	4	4	7	7	5
0,92	0,96	1,52	1,59	1,25	1,32	10	11	15	15	14	10	10	15	15	14	4	4	7	7	5
0,90	0,93	1,44	1,49	1,19	1,25	10	11	15	15	12	10	10	14	14	12	4	4	7	7	5
0,92	0,94	1,43	1,49	1,20	1,26	10	11	15	15	13	10	10	14	15	13	4	4	7	7	5
0,91	0,94	1,40	1,45	1,18	1,10	10	11	15	15	11	10	10	14	14	10	4	4	6	7	4
0,84	0,88	1,29	1,34	1,09	1,12	10	10	15	15	11	9	10	14	14	10	3	4	5	6	4
0,89	0,93	1,43	1,48	1,18	1,26	10	10	15	15	12	9	10	14	14	11	3	4	6	7	5
1,00	1,03	1,64	1,71	1,35	1,30	10	11	15	15	11	10	10	14	14	10	4	4	7	7	5
1,02	1,06	1,68	1,75	1,38	1,25	10	11	15	15	11	10	10	14	14	10	4	4	7	7	5
1,00	1,03	1,58	1,63	1,31	1,26	10	11	15	15	11	10	10	14	14	10	3	4	6	7	5
0,91	0,94	1,41	1,46	1,18	1,18	10	10	15	15	11	9	9	14	14	10	3	3	5	6	4
0,80	0,82	1,29	1,24	1,04	0,95	10	10	11	14	11	9	9	10	13	10	3	3	5	5	4
0,68	0,70	1,04	1,07	0,87	0,85	9	9	11	11	10	8	9	10	10	9	3	3	4	5	4
0,62	0,62	0,98	1,01	0,81	0,85	9	9	11	11	10	9	8	10	10	9	3	3	4	4	4




Fig. 3.19. Valorile inițiale ale funcției obiectiv (breaking points vs. cazul real)




Fig. 3.20. Valorile inițiale și finale ale funcției obiectiv (cazul real)




Fig. 3.21. Valorile finale ale funcției obiectiv (caz real vs. crisp)

În cadrul acestui paragraf a fost prezentată o metodă nouă de determinare a benzilor optimale de reglare a tensiunii în rețelele electrice, bazată pe modelarea fuzzy a profilurilor de sarcină. Comparăția realizată cu cazul real pune în evidență avantaje multiple de partea metodei propuse.

În plus, trebuie subliniat faptul că determinarea benzilor optimale de tensiune din rețelele electrice oferă dispecerilor posibilitatea de apreciere și control a tensiunilor și circulațiilor de putere reactivă în nodurile sistemului electroenergetic.

CAPITOLUL 4

PROBLEMA CORELAȚIEI ÎN MODELAREA FUZZY

4.1. Analiza de regresie și corelație

Înțelegerea funcționării sistemelor de orice natură impune studierea legăturilor dintre variabilele ce le caracterizează. În cazul variabilelor statistice, aceste legături pot fi analizate cu ajutorul metodei de regresie și corelație.

Metoda regresiei permite măsurarea și studierea relației care există între două sau mai multe variabile, precum și descoperirea legii relativ la forma legăturilor dintre variabile. Prin această metodă se încearcă, pe baza datelor unui eșantion, să se estimeze relația matematică dintre două sau mai multe variabile, adică să se estimeze valorile unei variabile în funcție de valorile altei variabile.

Analiza de corelație măsoară intensitatea legăturii dintre variabile. După forma modelului de regresie, corelația poate fi tratată ca o corelație simplă sau ca o corelație multiplă.

Intr-o cercetare bazată pe analiza de regresie și corelație trebuie rezolvate următoarele probleme [Jaba 00]:

- Identificarea existenței legăturii. Se rezolvă prin analiza logică a posibilității de existență a unei legături între variabilele considerate.
- Stabilirea sensului și formei legăturii. Se utilizează metode specifice analizei de regresie.
- Determinarea gradului de intensitate a legăturii. Se utilizează metode specifice analizei de corelație.

4.1.1. Analiza legăturilor statistice

Analiza legăturilor statistice vizează estimarea modelului de regresie și măsurarea intensității legăturii dintre variabile.

4.1.1.1. Metode elementare

a. Metoda seriilor statistice paralele interdependente

Analiza legăturilor statistice, prin această metodă, constă în compararea termenilor a două serii paralele interdependente x (variabila independentă) și y (variabila dependentă).

Cînd se compară două serii de timp, termenii lor se ordonează cronologic. Prin comparare se poate evidenția existența și direcția legăturii. Astfel, dacă ambele variabile comparate se modifică în același sens, există o legătură directă. Dacă variația lor este de sens diferit, corelația este inversă. Dacă cele două mărimi variază în mod independent, sau una variază și cealaltă rămîne constantă, între ele nu există legătură.

Această metodă se aplică în cazul seriilor cu un număr relativ mic de variabile, cînd există corespondența de la valoare, la valoare ($x_i, y_i, i = 1, \dots, n$).

b. Metoda tabelului de corelație

Această metodă presupune gruparea reprezentanților unui set de date simultan după ambele variabile corelate, x și y . Se recomandă să se folosească intervale de grupare egale și un număr de grupe aproximativ egal pentru ambele variabile.

În funcție de modul de distribuție a frecvențelor n_{ij} în tabelul respectiv se poate aprecia existența, direcția și intensitatea legăturii.

Tabelul 4.1. Tabel de corelație

$x \backslash y$	$y_1 \dots y_j \dots y_p$	$\sum_j n_{ij} = n_{i\bullet}$
x_1	$n_{11} \dots n_{1j} \dots n_{1p}$	$n_{1\bullet}$
-		
x_i	$n_{i1} \dots n_{ij} \dots n_{ip}$	$n_{i\bullet}$
-		
x_k	$n_{k1} \dots n_{kj} \dots n_{kp}$	$n_{k\bullet}$
$\sum_j n_{ij} = n_{\bullet j}$	$n_{\bullet 1} \dots n_{\bullet j} \dots n_{\bullet p}$	$n_{\bullet\bullet} = \sum_i \sum_j n_{ij}$

Dacă frecvențele n_{ij} sînt dispersate relativ uniform pe toată suprafața tabelului, nu există legătură între variabilele considerate. Cu cît acestea se concentrează în jurul diagonalelor tabelului, cu atît corelația este mai intensă [Jaba 00].

c. Metoda grafică

Metoda grafică presupune reprezentarea grafică a perechilor de valori ale variabilelor într-un sistem de axe de coordonate. Cu ajutorul acestei metode se pot stabili existența, sensul, forma și intensitatea corelației.

Metoda constă în construirea unui grafic de corelație ca în Fig. 4.1. Tipul de grafic prezentat în Fig. 4.1 se construiește în cazul corespondenței astfel: unei valori x_i îi va corespunde o valoare y_i (metoda seriilor paralele interdependente).




Fig. 4.1. Grafic de corelație

4.1.1.2. Metode analitice

Modelele analitice permit exprimarea matematică a formei legăturii și măsurarea numerică a intensității legăturii. Modelele de regresie au ca scop reprezentarea alurii distribuției a două variabile corelate. Prin curbele de regresie se prezintă corespondența între perechile de valori (x_i, y_i) .

Stabilirea și analiza modelului de regresie presupune efectuarea următorilor pași [Jaba 00]:

- Construirea graficului de corelație.
- Aproximarea, pe baza ajustării graficului de corelație, a formei legăturii printr-un model teoretic și scrierea ecuației corespunzătoare modelului de regresie ales.
- Determinarea parametrilor ecuației de regresie (pe baza metodei celor mai mici pătrate) și interpretarea regresiei în funcție de semnul și valoarea lor.

4.1.2. Modele de regresie cu două variabile

Legătura între două variabile y (variabila dependentă) și x (variabila independentă) se poate exprima printr-o funcție de regresie:

$$y_x = f(x) + e \quad (4.1)$$

unde:

$f(x)$ – este o funcție de variabila x , definită în sensul analizei matematice;

e – eroarea de aproximare.

Alegerea modelului care să exprime legătura dintre variabilele corelate depinde în mare măsură de volumul datelor cunoscute. Cu cât numărul observărilor este mai mare, cu atât crește șansa de a găsi o relație mai bună între variabilele corelate.

4.1.2.1. Modelul de regresie liniară

Modelul de regresie liniară simplă exprimă legătura dintre două variabile și ia forma:

$$y_x = a + bx + e \quad (4.2)$$

Relația (4.2) se numește ecuație de regresie și se reprezintă grafic printr-o dreaptă. În ecuația de regresie e este variabila eroare aleatoare $e_i = y_i - y_{xi}$, $i = 1, \dots, n$, iar a și b sînt parametri necunoscuți, ce urmează a fi determinați cu ajutorul metodei celor mai mici pătrate. Semnul parametrului de regresie b indică direcția legăturii dintre cele două variabile corelate:

$b > 0$ indică o legătură directă (pozitivă);

$b = 0$ nu există legătură;

$b < 0$ indică legătură inversă (negativă).

Valoarea acestui parametru arată gradul de dependență dintre variabile, respectiv cu cât crește sau scade y la o creștere sau la o scădere a variabilei x cu o unitate.

4.1.2.2. Modele de regresie neliniară

a. Modelul de regresie de tip parabolic

Pentru exprimarea acestui model, se utilizează, de regulă, parabola de gradul doi:

$$y_x = a + bx + cx^2 + e \quad (4.3)$$

unde parametrii a , b și c sînt necunoscuți și urmează a fi determinați cu ajutorul metodei celor mai mici pătrate.

b. Modelul de regresie de tip hiperbolic

Pentru exprimarea acestui model, se utilizează, de regulă, ecuația:

$$y_x = a + \frac{b}{x} + e \quad (4.4)$$

c. Modelul de regresie de tip exponențial

Acest model are următoarea formă:

$$y_x = ab^x + e \quad (4.5)$$

Pentru orice eșantion, expresia (4.5) poate fi liniarizată prin logaritmare:

$$\log y_x = \log a + x \log b \quad (4.6)$$

4.1.3. Măsurarea intensității legăturii dintre două variabile

Intensitatea legăturii între două variabile arată gradul de concentrare sau de împrăștiere a valorilor y în jurul liniei de regresie y_x . Intensitatea legăturii se poate determina cu ajutorul coeficientului de corelație și a raportului de corelație.

4.1.3.1. Coeficientul de corelație

Se folosește pentru măsurarea legăturii în cazul regresiei liniare simple. Pentru două variabile aleatoare x , y , coeficientul de corelație se notează cu $\rho(x, y)$ și este definit de relația:

$$\rho(x, y) = \frac{\text{cov}(x, y)}{\sigma_x \cdot \sigma_y} = \frac{\sum_i (x_i - \bar{x})(y_i - \bar{y})}{n \cdot \sigma_x \cdot \sigma_y}, \quad i = 1, \dots, n \quad (4.7)$$

unde:

$\text{cov}(x, y)$ – covarianța dintre variabilele x și y ;

$x_i, y_i, \bar{x}, \bar{y}$ – valorile variabilelor și nivelul mediu al acestora;

n – numărul perechilor de valori;

σ_x și σ_y – abaterea medie pătratică pentru x , respectiv y .

Între coeficientul de regresie b din relația (4.3) și coeficientul de corelație (corelare), definit de relația (4.7) există următoarea legătură:

$$\rho = b \cdot \frac{\sigma_x}{\sigma_y} \quad (4.8)$$

din care rezultă faptul că semnul coeficientului de corelație coincide cu semnul coeficientului de regresie, deoarece σ_x și $\sigma_y \geq 0$.

Valoarea coeficientului de corelație este cuprinsă între -1 și +1. Aceste două valori extreme reprezintă o legătură liniară perfectă (funcțională) între cele două variabile, "pozitivă", respectiv "negativă". Valoarea 0 semnifică absența legăturii între cele două variabile.

4.1.3.2. Raportul de corelație

Raportul de corelație este notat cu η și se definește prin relația:

$$\eta = \sqrt{\frac{\sigma_{y_x}^2}{\sigma_y^2}} \quad (4.9)$$

unde:

σ_y^2 – varianța generală, respectiv varianța variabilei y în raport cu media tuturor valorilor:

$$\sigma_y^2 = \frac{\sum (y_i - \bar{y})^2}{n} \quad (4.10)$$

$\sigma_{y_x}^2$ - varianța valorilor teoretice față de media lor

$$\sigma_{y_x}^2 = \frac{\sum (y_{x_i} - \bar{y})^2}{n} \quad (4.11)$$

Valoarea raportului de corelație este un număr cuprins între 0 și 1. Valoarea 1 indică existența unei legături funcționale, respectiv cazul când variația variabilei y depinde numai de variația variabilei x .

4.2. Corelarea sarcinilor în modelarea fuzzy

Calitatea și eficiența soluționării complexului de probleme privind planificarea optimă a regimurilor sistemelor electroenergetice (SEE), conducerea operativă, precum și planificarea optimă a dezvoltării SEE sînt în mare măsură determinate de precizia prognozelor și estimărilor de sarcină.

Estimarea cererii de putere și a consumului de energie electrică se realizează, în principiu, pornind de la datele retrospective privind evoluția consumului, care se înregistrează sistematic, se prelucerează prin metode adecvate și are în vedere: vîrfurile de sarcină zilnic, consumul orar, energia zilnică sau săptămînală etc. Pentru realizarea unei estimări cît mai exacte trebuie utilizată o bază consistentă de date, care trebuie să cuprindă valorile consumului de putere pentru o perioadă de timp suficient de îndelungată (minim 1 an) și (dacă este posibil) evoluțiile factorilor demografici, climatici și a indicatorilor economici din zona respectivă, în perioada considerată. Aceste date trebuie să fie selectate și prelucrate statistic pentru eliminarea erorilor grosolane, după care se încearcă stabilirea unei corelații între consumurile de putere/energie și unul sau mai mulți parametri considerați ca variabile independente.

Practica a arătat că succesul aplicării unei metode de estimare depinde de îndeplinirea unor cerințe specifice, cum ar fi: alegerea corectă a intervalului de estimare, robustețea metodei, veridicitatea datelor inițiale, adaptabilitatea, includerea influenței factorilor meteorologici, economicitatea eforturilor de calcul etc.

Pentru estimarea sarcinilor, în particular a sarcinilor de vîrf, s-au dezvoltat diferite metode și formulări matematice [Sargent 94], [Broadwater 97], [Nazarko 99]. Cea mai mare parte a metodelor propuse folosesc dependența dintre puterea la vîrfurile de sarcină și energia consumată anual (lunar). Pentru a remedia caracterul incert al informațiilor ce există la nivelul stațiilor/posturilor de transformare s-au pus la punct și variante fuzzy adecvate.

Astfel, în cadrul acestui capitol s-a urmărit stabilirea unor metodologii practice de estimare și prognoză a curbelor de sarcină activă și reactivă, a puterilor active și

reactive consumate la vârful de sarcină în stațiile/posturile de transformare, folosind corelația de puteri și modele fuzzy pentru puterile nodale. În continuare, se prezintă posibilitățile de utilizare ale acestor modele la analiza regimurilor rețelelor de transport și distribuție.

4.2.1. Modelul fuzzy cu sarcini necorelate

Intrucât problema fuzzificării sarcinilor din nodurile rețelelor electrice, în general, și a încărcării transformatoarelor în particular, este o chestiune foarte importantă, în cele ce urmează vom prezenta o variantă de fuzzificare a încărcării transformatoarelor, folosită frecvent în analiza regimurilor rețelelor electrice [Cârțină 01/1].

Calea cea mai simplă de estimare a sarcinilor din nodurile rețelelor electrice este bazată pe ipoteza că toate tipurile de sarcini se comportă/variază identic, având un coeficient de corelație cât mai aproape de unitate. În caz contrar, calculele de modelare/estimare se complică și introducerea unor corecții nu poate fi evitată.

Descrierea aproximativă a sarcinii din nodurile unei rețele de distribuție sub forma unui model fuzzy face apel la intuiția și experiența acumulată în timp a proiectantului sau a operatorului de rețea. Convențional, caracterul imprecis al datelor privind puterile cerute în noduri poate fi evaluat, clasificând consumul într-un nod, în funcție de mărimea lui, în categorii lingvistice, cu ajutorul următoarelor declarații: **Foarte Mic** (VS - Very Small), **Mic** (S - Small), **Mediu** (M - Medium), **Mare** (H - High) și **Foarte Mare** (VH - Very High). Fiecărei categorii lingvistice i se asociază un număr fuzzy, care implică o funcție de apartenență. Aceasta exprimă distribuția posibilității de realizare a unei sarcini de o anumită valoare.




Fig. 4.2. Nivelele lingvistice de sarcină, reprezentarea "breaking points"

Fuzzificarea sarcinilor din nodurile rețelelor de distribuție se bazează pe cunoașterea nivelelor de încărcare existente sau estimate, determinate pentru fiecare din cele 24 ore, în zilele de vîrf de sarcină, **Foarte Mic (VS - Very Small)**, **Mic (S - Small)** etc.

Astfel, se poate proceda la împărțirea sarcinilor, pe baza încărcării transformatoarelor din stațiile/posturile de transformare respective, în cinci categorii lingvistice (de sarcină): VS, S, M, H, VH, după valoarea gradului de încărcare a acestora, la vîrf de sarcină, K_p , Fig. 4.2.

4.2.2. Necesitatea corelării puterilor în modelele fuzzy

Dacă pentru unele din stațiile/posturile de transformare deținem date suficiente pentru o estimare de calitate a sarcinilor în general și a vîrfului de sarcină în special, pentru restul stațiilor/posturilor de transformare puterea cerută la vîrf de sarcină se poate determina pe baza unor studii de corelare, așa cum se va arăta în continuare.




Fig.4.3. Necorelarea dintre sarcinile fuzzy P și Q




Fig. 4.4. Corelarea dintre sarcinile fuzzy P și Q

În Fig. 4.3 este reprezentată necorelarea sarcinii fuzzy, pentru puterile active și reactive, exprimate prin numere fuzzy trapezoidale. Această reprezentare conduce la următoarea concluzie: presupunînd un astfel de model, toate combinațiile dintre valorile lui P și Q sînt posibile, Fig. 4.3. Prin urmare, acest model va fi în multe situații departe de realitate. Normal ar trebui introduse informații suplimentare de corelare între generare și consum, între puterea activă și cea reactivă. Pentru clarificarea acestei probleme, să considerăm modelul sarcinii fuzzy reprezentat în Fig. 4.4. În acest caz, pentru aceleași funcții de apartenență pentru P și Q, reprezentate în Fig. 4.3, funcția de apartenență comună PQ este complet diferită, adică o dreaptă. Explicația este următoare: presupunînd faptul că valorile pentru P și

Q au fost intenționat corelate, pornind de la valori minime pentru P și Q, o creștere a lui P urmează să implice o creștere și a lui Q.

Situațiile din cele două figuri de mai sus corespund unor cazuri extreme: Fig. 4.3 – sarcini fuzzy P și Q necorelate, Fig. 4.4 – sarcini fuzzy P și Q cu corelare constantă (liniară).

În realitate lucrurile stau pe undeva, pe la mijloc. Dacă se acceptă modelul de regresie liniară simplă pentru legătura între valorile medii ale celor două puteri rezultă:

$$Q = \rho_{QP} \frac{\sigma_Q}{\sigma_P} \cdot P + k_{QP} \quad (4.12)$$

$$\rho_{PQ} = \frac{C_{PQ}}{\sigma_P \cdot \sigma_Q} \quad (4.13)$$

$$C_{PQ} = \overline{PQ} - \bar{P} \cdot \bar{Q} \quad (4.14)$$

$$\sigma_P^2 = \overline{P^2} - \bar{P}^2 \quad (4.15)$$

$$\sigma_Q^2 = \overline{Q^2} - \bar{Q}^2 \quad (4.16)$$

unde:

ρ_{QP} – coeficientul de corelație (corelare) între variabilele P și Q;

C_{PQ} – covarianța între variabilele P și Q;

σ_P, σ_Q – abaterea medie patrată pentru cele două variabile (P, Q).

Supralinierea indică valoarea medie a mărimii (expresiei) respective, iar k_{QP} urmează să se determine pentru fiecare caz în parte, pe baza unor studii cât mai concrete.

În această situație, pentru a fi posibilă și reprezentarea nuanțată a cazurilor în care mărimile P și Q variază în sensuri contrare, se impune introducerea unei benzi de variație, Fig. 4.5.




Fig.4.5. Corelarea nuanțată a sarcinilor fuzzy P și Q

4.3. Estimarea puterilor la vârfului de sarcină

4.3.1. Folosirea corelației fuzzy

Punctul de plecare corespunzător metodei corelațiilor fuzzy este analiza statistică a graficelor de sarcină ale puterilor active/reactive din stațiile/posturile de transformare din sistemul analizat.

1. Calculul valorii coeficienților de corelație dintre seturile de date corespunzătoare puterilor active înregistrate în fiecare stație/post de transformare din sistemul analizat și a dispersiilor acestora.
2. Alegerea graficului de referință în raport cu care se studiază corelarea. Ca referință se poate alege suma valorilor orare ale puterilor active din stațiile/posturile de transformare, adică profilul curbei însumate a puterilor din sistemul analizat.
3. Determinarea sarcinii maxime și a orei la care se înregistrează, pentru graficul (profilul) de referință.
4. Calculul coeficienților $k_{P_r P_i}$ și k_{P_i} cu ajutorul relațiilor:

$$k_{P_r P_i} = \rho_{P_r P_i} \cdot \frac{\sigma_{P_i}}{\sigma_{P_r}}; \quad i = 1, \dots, N \quad (4.17)$$

$$k_{P_i} = \sum_{j=1}^h (P_{ij} - k_{P_r P_i} \cdot P_{rj}) / L_h; \quad i = 1, \dots, N \quad (4.18)$$

unde:

P_r – puterea activă corespunzătoare profilului de referință;

P_i – puterea activă din stația/postul de transformare i a sistemului analizat;

N – numărul total de stații/posturi de transformare din sistemul analizat;

L_h – dimensiunea ferestrei de analiză ($h = 24, 7, \dots$).

5. Determinarea valorii puterilor active din stațiile/posturile de transformare la ora vârfului de sarcină:

$$P_i = k_{P_r P_i} \cdot P_{r \max} + k_{P_i} \quad (4.19)$$

unde:

$P_{r \max}$ – sarcina maximă corespunzătoare profilului de referință;

P_i – valoarea puterii active din stația/postul de transformare i la ora vârfului de sarcină a sistemului analizat.

Fig. 4.6. Algoritmul de estimare a puterilor la vârful de sarcină prin metoda regresiei liniare

Această analiză statistică poate fi realizată cu ajutorul a diferite ferestre de timp, alese de utilizator, în funcție de particularitățile sistemului. Astfel, în estimarea sarcinii înregistrate în stațiile/posturile de transformare la ora vârfului de sarcină al sistemului, pot fi folosite diferite ferestre de timp: fereastra de 24h, fereastra de 7h ($t_{PL} - 3h; t_{PL} + 3h$), fereastra de 7h ($t_{PL} - 4h; t_{PL} + 2h$) etc, unde t_{PL} este ora la care se înregistrează vârful de sarcină.

Etapele algoritmului metodei de estimare a puterilor la vârful de sarcină al sistemului, utilizând metoda regresiei liniare, sînt prezentate în Fig. 4.6 [Cârțină 03/1].

Dacă se cunosc și graficele de sarcină ale puterilor reactive, atunci, pentru determinarea valorilor puterilor reactive din stațiile/posturile de transformare, la ora vârfului de sarcină al sistemului, se parcurg aceiași pași, ca cei prezentați în algoritmul de mai sus. Graficul de referință în raport cu care se studiază corelarea rămîne același.

Astfel, valorile puterilor reactive din stațiile/posturile de transformare, la ora vârfului de sarcină a sistemului analizat pot fi determinate cu relația:

$$Q_i = k_{P,Q_i} \cdot P_{r \max} + k_{Q_i} \quad (4.20)$$

unde coeficienții k_{P,Q_i} și k_{Q_i} sînt calculați cu relațiile:

$$k_{P,Q_i} = \rho_{P,Q_i} \cdot \frac{\sigma_{Q_i}}{\sigma_{P_r}}; \quad i = 1, \dots, N \quad (4.21)$$

$$k_{Q_i} = \sum_{j=1}^h (Q_{ij} - k_{P,Q_i} \cdot P_{rj}) / L_h; \quad i = 1, \dots, N \quad (4.22)$$

Pentru că în multe situații nu se dispune de date adecvate privind sarcina din fiecare stație/post transformare la ora vârfului de sarcină, se propune, în continuare, utilizarea variabilelor fuzzy cu funcții de apartenență trapezoidale, pentru descrierea sarcinilor incerte din nodurile respective.

Pornind de la analiza statistică aplicată în cazul regresiei liniare, în continuare, se alege, pe baza experienței, pentru sarcina maximă din graficul de referință, trapezul fuzzy din Fig. 4.7.

Astfel, cu ajutorul coeficienților k_{P,P_i} , k_{P_i} , k_{P,Q_i} și k_{Q_i} și a trapezului fuzzy din Fig. 4.7 se determină trapezele fuzzy corespunzătoare puterilor active și reactive din stațiile/posturile de transformare, la ora vârfului de sarcină al sistemului analizat, utilizînd relațiile 4.19 și 4.20.




Fig. 4.7. Modelul fuzzy corespunzător graficului de referință

În multe situații, în sistemele de distribuție nu se dețin informații despre graficele de sarcină ale puterilor reactive din posturile de transformare astfel încât, în acest caz, pentru determinarea valorilor puterilor reactive, la ora vîrfului de sarcină al sistemului, se pot folosi următoarele două variabile fuzzy: puterile active determinate cu trapezul fuzzy din Fig. 4.7 și relațiile 4.19 și 4.20 și factorul de putere $\cos \varphi$, considerat ca variabilă fuzzy cu funcție de apartenență trapezoidală, Fig. 4.8.




Fig. 4.8. Modelul fuzzy corespunzător factorului de putere

Trapezul fuzzy folosit pentru factorul de putere, Fig. 4.8, corespunde unor posturi de transformare ce alimentează rețele urbane cu consumatori preponderent rezidențiali. Deoarece se constată că factorul de putere crește odată cu puterea activă absorbită de consumatori, cele două variabile fuzzy trebuie să fie corelate.

Folosind modelele fuzzy pentru puterea activă și factorul de putere, puterile reactive din posturile de transformare, la vîrf de sarcină al sistemului rezultă din relația:

$$Q = P \cdot \tan \varphi \quad (4.23)$$

4.3.2. Estimarea puterilor la vârful de sarcină în rețelele de 110 kV

Folosind o bază de date corespunzătoare sucursalelor de distribuție a energiei electrice din zona Moldovei, pentru ziua caracteristică de iarnă (16.1.2002), pe baza principiilor și relațiilor prezentate în paragraful 4.3.1 s-au făcut mai întâi prelucrările statistice necesare formalizării și aplicării tehnicilor fuzzy cu ajutorul algoritmului din Fig. 4.6 [Cârțină 03/3].

În acest sens s-a urmărit, în principal, stabilirea unor metodologii practice de estimare a curbelor de sarcină ale puterilor activă și reactivă, a puterilor active și reactive consumate la vârful de sarcină, chiar și în condițiile unor date incomplete privind rețelele electrice de 110 kV. Sistemul studiat conține 155 de noduri de 110 kV ce aparțin celor 6 sucursale Electrica din Moldova și are vârful de sarcină la ora 19 (vîrf de sarcină iarna (VSI)).

În felul acesta, s-au determinat parametrii de coerență, reprezentați de coeficienții de corelație ai graficele de sarcină ale puterilor active și reactive corespunzătoare nodurilor din cadrul sucursalelor de distribuție a energiei electrice din Moldova, cu graficul de sarcină al puterii active totale la nivelul filialei Electrica Moldova.

Pentru determinarea coeficienților de corelație s-au folosit diferite ferestre de timp, în funcție de scopul urmărit ulterior:

- fereastra 24 h;
- fereastra 7h (VSI ± 3 h);
- fereastra 7 h (VSI +4h, VSI-2h).

Prima dintre aceste opțiuni, fereastra de 24h, se poate utiliza cu succes pentru estimări ale sarcinii în oricare nod al rețelei de 110 kV, folosind puterea maximă consumată la vîrf de sarcină iarna (VSI) la nivelul filialei Electrica Moldova (valoarea vîrfului de sarcină iarna a fost de 822,247 MW). Dacă se urmărește doar calculul mai exact al puterilor respective la VSI este suficientă fereastra de 7h (VSI ± 3 h).

Plecînd de la graficul de sarcină al puterilor active și reactive din nodurile rețelei de 110 kV ce aparțin sucursalelor Electrica s-au calculat coeficienții dreptelor de regresie pentru puterile active și reactive, în raport cu profilul de referință comun (suma puterilor pe sucursalele Electrica). În Fig. 4.9 – 4.12 sînt exemplificate aceste drepte de regresie pentru un nod reprezentativ (stația Centru – Electrica Iași). Utilizînd relațiile (4.19) și (4.20) se calculează valorile puterilor active și reactive la vîrf de sarcină iarna (VSI) pentru fiecare nod din rețeaua de 110 kV.

Pe baza acestor valori și considerînd trapezul fuzzy, pentru profilul de referință:

$$x_1 = x_2 = 0,95 P_{\max}$$

$$x_3 = P_{\max}$$

$$x_4 = 1,01 P_{\max}, \quad P_{\max} = \text{VSI}$$

se obțin trapezele fuzzy pentru puterile active și reactive pe fiecare sucursală Electrica, pentru vârful de sarcină iarna. În Tabelul 4.2 sînt prezentate, ca exemplu, valorile "breaking points" ale trapezelor fuzzy asociate nodurilor din cadrul sucursalei Electrica Bacău, valori calculate cu modelul fuzzy.



În Fig. 4.9 – 4.12 puterile sînt prezentate în valori absolute, iar în Tabelul 4.2 erorile sînt date în mărimi procentuale, raportate la puterea maximă (822,247 MW).



Semnificația mărimilor din cadrul Tabelul 4.2 este următoarea:

- $P_1 \dots P_4, Q_1 \dots Q_4$ – reprezintă valorile "breaking points" ale trapezului fuzzy pentru puterile active, respectiv, reactive corespunzătoare nodurilor de 110 kV, la vîrf de sarcină iarna;
- P_f, Q_f – valorile crisp ale puterilor active, respectiv, reactive, din nodurile de 110 kV, la vîrf de sarcină iarna, obținute în urma operației de defuzzificare;
- P_e, Q_e – valorile determinate cu metoda regresiei liniare pentru puterile active, respectiv, reactive, din nodurile de 110 kV, la vîrf de sarcină iarna, obținute pentru fereastra de analiză 7h ($19 (\text{VSI}) \pm 3\text{h}$);
- P_m, Q_m – valorile puterilor active, respective, reactive, din nodurile de 110 kV, la vîrf de sarcină iarna, obținute prin măsurători de către sucursalele Electrica din Moldova;
- Er_P, Er_Q – reprezintă erorile procentuale calculate cu relațiile:

$$Er_P = \frac{P_m - P_f}{P_{\max}} \cdot 100 [\%]; \quad Er_Q = \frac{Q_m - Q_f}{P_{\max}} \cdot 100 [\%] \quad (4.24)$$

- $P_{\max}$ – valoarea maximă a puterii active corespunzătoare profilului de referință (822,247 MW).



Fig. 4.11. Graficul de corelație $Q_{\text{Centru-Iași}} (P_{\Sigma} \text{ Electrica})$ – Fereastra 24hFig. 4.12. Graficul de corelație $Q_{\text{Centru-Iași}} (P_{\Sigma} \text{ Electrica})$ – Fereastra 7h (ora 19 (VSI)± 3h)

Tabelul 4.2. $P_{\text{Electrica Bacău}}$, $Q_{\text{Electrica Bacău}}$ ($P_{\Sigma \text{ Electrica}}$), Modelul fuzzy, fereastră 7h (ora 19 (VSI) $\pm$ 3h)

Nod	P1 [MW]	P2 [MW]	P3 [MW]	P4 [MW]	P _r [MW]	P _e [MW]	P _m [MW]	Er _p [%]	Q1 [MVar]	Q2 [MVar]	Q3 [MVar]	Q4 [MVar]	Q _r [MVar]	Q _e [MVar]	Q _m [MVar]	Er _q [%]
1	0,88	0,88	0,86	0,86	0,87	0,86	1,30	-0,05	0,34	0,34	0,35	0,35	0,35	0,35	0,40	-0,01
2	0,70	0,70	0,61	0,59	0,65	0,61	0,40	0,03	0,35	0,35	0,31	0,31	0,33	0,31	0,40	-0,01
3	2,20	2,20	2,47	2,52	2,35	2,47	2,40	-0,01	1,32	1,32	1,48	1,51	1,41	1,48	1,40	0,00
4	5,34	5,34	5,54	5,58	5,45	5,54	5,50	-0,01	1,13	1,13	1,07	1,06	1,10	1,07	1,00	0,01
5	3,54	3,54	3,69	3,72	3,62	3,69	3,70	-0,01	2,11	2,11	2,19	2,20	2,15	2,19	2,20	-0,01
6	7,44	7,44	7,64	7,68	7,55	7,64	7,80	-0,03	2,24	2,24	2,66	2,74	2,47	2,66	2,80	-0,04
7	33,92	33,92	33,56	33,49	33,72	33,56	33,70	0,00	16,33	16,33	16,21	16,19	16,27	16,21	16,20	0,01
8	38,76	38,76	39,02	39,07	38,90	39,02	39,00	-0,01	4,14	4,10	4,13	4,13	4,14	4,13	4,00	0,02
9	5,93	5,90	5,93	5,93	5,93	5,93	5,50	0,05	0,58	0,58	0,60	0,60	0,59	0,60	1,00	-0,05
10	16,95	16,95	18,85	19,24	18,00	18,85	18,00	-0,00	9,76	9,76	10,75	10,94	10,30	10,75	10,00	0,04
11	14,76	14,76	14,98	15,02	14,88	14,98	15,00	-0,01	8,50	8,50	8,50	8,50	8,50	8,50	8,50	0,00
12	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
13	3,24	3,24	2,89	2,82	3,05	2,89	3,00	0,01	1,55	1,55	1,35	1,31	1,44	1,35	1,50	-0,01
14	3,45	3,45	3,35	3,33	3,40	3,35	3,00	0,05	1,06	1,06	1,05	1,05	1,06	1,05	1,00	0,01
15	1,09	1,09	1,32	1,36	1,21	1,32	2,20	-0,12	0,47	0,47	0,55	0,56	0,51	0,55	0,00	0,06
16	1,46	1,46	1,50	1,50	1,48	1,50	2,20	-0,09	0,68	0,68	0,64	0,64	0,66	0,64	0,80	-0,02
17	8,24	8,24	8,74	8,84	8,52	8,74	9,00	-0,06	3,45	3,45	3,58	3,60	3,52	3,58	3,50	0,00
18	3,33	3,33	3,70	3,77	3,53	3,70	3,80	-0,03	1,94	1,94	2,14	2,18	2,05	2,14	2,20	-0,02
19	39,78	39,78	45,90	47,12	43,14	45,90	42,00	0,14	2,98	2,98	2,88	2,86	2,93	2,88	3,00	-0,01
20	15,00	15,00	16,37	16,65	15,76	16,37	16,30	-0,07	3,97	3,97	4,26	4,32	4,13	4,26	4,30	-0,02
21	14,77	14,77	15,42	15,55	15,13	15,42	15,50	-0,05	3,97	3,97	4,02	4,03	3,99	4,02	3,70	0,04
22	7,82	7,82	7,99	8,03	7,92	7,99	8,00	-0,01	0,73	0,73	0,79	0,80	0,76	0,79	1,00	-0,03
23	11,52	11,52	11,99	12,09	11,78	11,99	12,00	-0,03	7,19	7,19	8,16	8,35	7,72	8,16	8,00	-0,03
24	4,57	4,57	4,84	4,90	4,72	4,84	4,90	-0,02	1,57	1,57	1,78	1,83	1,69	1,78	2,00	-0,04
25	5,95	5,95	6,21	6,26	6,09	6,21	6,10	-0,00	0,94	0,94	0,92	0,92	0,93	0,92	1,00	-0,01
26	2,17	2,17	2,17	2,17	2,17	2,17	2,10	0,01	1,26	1,26	1,26	1,26	1,26	1,26	1,20	0,01
27	5,47	5,47	5,85	5,93	5,68	5,85	6,00	-0,04	1,06	1,06	1,09	1,09	1,08	1,09	1,10	-0,00
28	9,46	9,46	9,40	9,39	9,43	9,40	9,00	0,05	5,42	5,42	5,25	5,22	5,33	5,25	4,80	0,06
29	1,38	1,38	1,50	1,52	1,45	1,50	1,30	0,02	0,41	0,41	0,46	0,48	0,44	0,46	0,40	0,00
30	4,31	4,31	4,41	4,43	4,36	4,41	4,70	-0,04	1,31	1,31	1,34	1,35	1,33	1,34	1,40	-0,01
31	8,04	8,04	8,45	8,54	8,27	8,45	8,50	-0,03	9,22	9,22	9,38	9,42	9,31	9,38	9,50	-0,02

4.3.3. Estimarea puterilor la vârful de sarcină în rețelele de distribuție

În acest paragraf se prezintă un exemplu pentru estimarea puterilor active din posturile de transformare ale unei rețele de distribuție de 20 kV, la ora vârfului de sarcină (VS) corespunzător acesteia, utilizând metoda regresiei liniare descrisă în paragraful 4.2.3.

În exemplul de calcul s-a considerat o rețea de distribuție urbană, de 20 kV, formată din 34 PT 20/0,4 kV, care are vârful de sarcină la ora 15 [Moise 02].

Plecând de la variația în timp a puterilor active din nodurile rețelei de 20 kV s-au calculat coeficienții dreptelor de regresie, în raport cu profilul referinței comune (suma valorilor orare ale puterilor active din posturile de transformare la rețelei de distribuție) pentru puterile active. În Fig. 4.13 – 4.16 sînt exemplificate dreptele de regresie pentru diferite ferestre de analiză, pentru un nod reprezentativ (nodul 28). Utilizând relația (4.19) se calculează valorile puterilor active la vârful de sarcină pentru fiecare nod din rețeaua de 20 kV, corespunzător diferitelor ferestre de timp:

- fereastra de 24h;
- fereastra 7h (ora 15 (VS) $\pm$ 3h);
- fereastra 7h (ora 15 (VS) – 4h; ora 15 (VS) + 2h);
- fereastra 7h (ora 15 (VS) – 5h; ora 15 (VS) + 1h);

Valorile respective sînt prezentate în Tabelul 4.3.




Fig. 4.13. Graficul de corelație $P_{28}(P_r)$, fereastra 24h




Fig. 4.14. Graficul de corelație $P_{28}(P_r)$, fereastra 7h (15 (VS) $\pm$ 3h)




Fig. 4.15. Graficul de corelație $P_{28}(P_r)$, fereastra 7h (15(VS)-4h; 15(VS)+2h)




Fig. 4.16. Graficul de corelație $P_{28}(P_r)$, fereastra 7h (15(VS)-4h; 15(VS)+2h)

Pe baza valorilor obținute pentru fereastra de 7h (ora 15 (VS) – 5h; ora 15 (VS) + 1h), pentru care s-au obținut cele mai mici erori de estimare, și considerând trapezul fuzzy pentru profilul de referință (Fig. 4.7) se obțin trapezele fuzzy pentru puterile active, la vârful de sarcină.

Tabelul 4.3. Puterile active calculate cu modelul regresiei liniare

PT	Valori măsurate	Puterile estimate și erorile pentru diferite ferestre de analiză							
	P_m [kW]	Fereastra 24h		Fereastra 7h ($t_{PL}-4h$; $t_{PL}+2h$)		Fereastra 7h ($t_{PL}-3h$; $t_{PL}+3h$)		Fereastra 7h ($t_{PL}-5h$; $t_{PL}+1h$)	
		P_e [kW]	Er_P [%]	P_e [kW]	Er_P [%]	P_e [kW]	Er_P [%]	P_e [kW]	Er_P [%]
1	240,50	239,87	-0,25	241,24	0,31	242,91	1,00	239,18	-0,54
2	216,30	224,75	3,90	220,51	1,95	221,72	2,50	214,72	-0,73
3	311,10	346,66	11,43	321,91	3,47	325,90	4,75	315,86	1,53
4	436,00	397,62	-8,80	442,13	1,40	448,77	2,92	430,60	-1,23
5	410,70	381,80	-7,03	414,33	0,88	404,67	-1,46	422,27	2,81
6	420,30	422,38	0,49	411,41	-2,11	415,96	-1,03	407,03	-3,15
7	600,60	614,11	2,24	604,11	0,58	597,28	-0,55	610,54	1,65
8	617,70	609,06	-1,39	611,49	-1,00	605,77	-1,93	622,15	0,72
9	561,20	560,48	-0,12	561,27	0,01	553,07	-1,44	567,94	1,20
10	208,70	213,18	2,15	205,07	-1,73	211,44	1,31	200,76	-3,80
11	617,00	607,32	-1,56	612,51	-0,72	598,10	-3,06	626,26	1,50
12	588,10	562,06	-4,42	588,08	-0,00	593,15	0,86	586,35	-0,29
13	404,90	408,13	0,79	389,69	-3,75	378,81	-6,44	406,06	0,28
14	357,20	397,83	11,37	360,54	0,93	362,83	1,57	359,61	0,67
15	360,40	384,70	6,74	356,33	-1,12	354,75	-1,56	363,06	0,73
16	365,60	371,42	1,59	376,21	2,90	388,43	6,24	356,33	-2,53
17	545,70	596,06	9,22	577,80	5,88	596,63	9,33	543,04	-0,48
18	254,90	257,03	0,83	258,62	1,46	257,09	0,86	260,77	2,30
19	191,30	213,61	11,66	196,52	2,73	202,63	5,92	191,78	0,25
20	168,10	196,46	16,87	175,47	4,38	183,60	9,22	162,46	-3,35
21	667,50	622,26	-6,77	633,51	-5,09	618,86	-7,28	662,08	-0,81
22	421,40	409,54	-2,81	423,75	0,55	414,28	-1,68	428,87	1,77
23	440,40	388,90	-11,69	419,91	-4,65	411,62	-6,53	436,36	-0,91
24	637,00	642,21	0,81	620,27	-2,62	633,43	-0,56	619,42	-2,75
25	452,30	444,02	-1,82	453,28	0,21	459,63	1,62	448,10	-0,92
26	623,70	534,84	-14,24	622,70	-0,16	615,64	-1,29	616,91	-1,08
27	402,20	392,49	-2,41	403,55	0,33	394,50	-1,91	408,35	1,53
28	671,80	677,40	0,83	682,12	1,53	686,71	2,21	679,72	1,18
29	634,10	643,68	1,51	638,69	0,72	640,00	0,93	628,87	-0,82
30	594,20	569,71	-4,12	606,74	2,11	613,92	3,32	594,83	0,10
31	388,10	437,63	12,76	392,07	1,02	386,38	-0,44	399,55	2,95
32	329,80	341,49	3,54	333,66	1,17	332,31	0,76	330,87	0,32
33	571,00	568,94	-0,36	551,65	-3,38	563,85	-1,25	549,30	-3,80
34	635,40	667,39	5,03	637,90	0,39	630,39	-0,78	655,06	3,09

În Fig. 4.17 sînt reprezentate erorile de estimare corespunzătoare modelului regresiei liniare. Se constată că în cazul ferestrei de analiză 7h ($t_{PL}-5h$; $t_{PL}+1h$) erorile sînt mai mici decît în cazul folosirii altor ferestre de analiză, eroarea medie fiind de 1,48 %. Erorile au fost calculate cu ajutorul relației:

$$Er_p = \frac{P_{e(f)} - P_m}{P_m} 100 \quad [\%] \quad (4.25)$$




Fig. 4.17. Erorile corespunzătoare diferitelor ferestre de timp

- | | | |
|----|---|-----------------------------|
| a) | Fereastra de timp 24h; | Eroarea medie este: 4,90 %; |
| b) | Fereastra de timp 7h ($t_{PL}-3h$; $t_{PL}+3h$); | Eroarea medie este: 2,70 %; |
| c) | Fereastra de timp 7h ($t_{PL}-4h$; $t_{PL}+2h$); | Eroarea medie este: 1,75 %; |
| d) | Fereastra de timp 7h ($t_{PL}-5h$; $t_{PL}+1h$); | Eroarea medie este: 1,48 %. |

În continuare, trapezele fuzzy pentru puterile reactive se vor obține utilizând trapezul fuzzy pentru $\cos \varphi$ (Fig. 4.8), trapezele fuzzy corespunzătoare puterilor active, determinate pe baza relației (4.19) și trapezului fuzzy din Fig. 4.7. Valorile “breaking points” corespunzătoare trapezelor fuzzy pentru puterile active sînt prezentate în Tabelul 4.4.

Tabelul 4.4. Rezultatele obținute cu modelul fuzzy fereastră 7h ($t_{PL}-5h$; $t_{PL}+1h$)

PT	Valorile “Breaking points”				Valori crisp	Valori măsurate	Eroarea
	P1 [kW]	P2 [kW]	P3 [kW]	P4 [kW]	P _f [kW]	P _m [kW]	Er _p [%]
1	203,97	221,57	239,18	256,78	230,37	240,50	-4,20
2	181,20	197,96	214,72	231,47	206,34	216,30	-4,60
3	262,84	289,35	315,86	342,37	302,61	311,10	-2,72
4	331,89	381,24	430,60	479,95	405,92	436,00	-6,89
5	396,70	409,48	422,27	435,05	415,88	410,70	1,26
6	364,66	385,85	407,03	428,22	396,44	420,30	-5,67
7	563,46	587,00	610,54	634,07	598,77	600,60	-0,30
8	553,52	587,83	622,15	656,46	604,99	617,70	-2,05
9	521,49	544,71	567,94	591,16	556,32	561,20	-0,86
10	162,19	181,47	200,76	220,05	191,12	208,70	-8,42
11	570,93	598,59	626,26	653,93	612,43	617,00	-0,74
12	532,85	559,60	586,35	613,10	572,98	588,10	-2,57
13	411,23	408,65	406,06	403,48	407,35	404,90	0,60
14	316,62	338,11	359,61	381,10	348,86	357,20	-2,33
15	334,89	348,97	363,06	377,14	356,01	360,40	-1,21
16	301,29	328,81	356,33	383,84	342,57	365,60	-6,29
17	439,03	491,04	543,04	595,04	517,04	545,70	-5,25
18	216,96	238,86	260,77	282,67	249,82	254,90	-1,99
19	169,93	180,85	191,78	202,70	186,32	191,30	-2,60
20	145,98	154,22	162,46	170,70	158,34	168,10	-5,80
21	626,18	644,13	662,08	680,03	653,11	667,50	-2,15
22	419,03	423,95	428,87	433,79	426,41	421,40	1,19
23	390,01	413,19	436,36	459,54	424,77	440,40	-3,54
24	549,63	584,52	619,42	654,31	601,97	637,00	-5,49
25	395,52	421,81	448,10	474,39	434,96	452,30	-3,83
26	544,85	580,88	616,91	652,94	598,90	623,70	-3,97
27	401,53	404,94	408,35	411,76	406,65	402,20	1,10
28	587,35	633,54	679,72	725,91	656,63	671,80	-2,25
29	590,84	609,85	628,87	647,89	619,36	634,10	-2,32
30	518,79	556,81	594,83	632,85	575,82	594,20	-3,09
31	391,53	395,54	399,55	403,56	397,55	388,10	2,43
32	306,86	318,86	330,87	342,87	324,87	329,80	-1,49
33	480,38	514,84	549,30	583,75	532,07	571,00	-6,81
34	626,36	640,71	655,06	669,41	647,89	635,40	1,96

În Fig. 4.18 sînt reprezentate erorile de estimare corespunzătoare modelului fuzzy, calculate cu relația (4.25).




Fig. 4.18. Erorile corespunzătoare modelului fuzzy

- | | |
|--|-----------------------------|
| a) Fereastra de timp 24h; | Eroarea medie este: 5,35 %; |
| b) Fereastra de timp 7h ($t_{PL}-3h$; $t_{PL}+3h$); | Eroarea medie este: 2,82 %; |
| c) Fereastra de timp 7h ($t_{PL}-4h$; $t_{PL}+2h$); | Eroarea medie este: 2,49 %; |
| d) Fereastra de timp 7h ($t_{PL}-5h$; $t_{PL}+1h$); | Eroarea medie este: 3,08 %. |

4.3.4. Îmbunătățirea estimării puterilor prin tehnici de grupare spațială

Pentru îmbunătățirea rezultatelor metodei corelațiilor fuzzy se poate proceda la o nuanțare a categoriilor de noduri. Astfel, se face mai întâi o împărțire a nodurilor de 20 kV, din sistemul de distribuție analizat, într-un număr de 3-5 grupe, în funcție de profilul sarcinii active și de energia consumată anual de fiecare, folosind o metodă de grupare spațială. Pentru fiecare din grupele rezultate se determină un

trapez fuzzy, pe baza analizei statistice a caracteristicilor elementelor din grupa respectivă. În felul acesta se poate obține o funcție de apartenență pentru grupele respective care țin seama de structura acesteia.

Astfel, se determină mai întâi graficul (profilul) tip de sarcină normalizată, prin împărțirea puterilor orare la energia activă totală consumată în ziua de sarcină maximă a sistemului analizat:

$$p_i^h = \frac{P_i^h}{E_s}; \quad h = 1, \dots, 24, \quad i = 1, \dots, N_{RP} \quad (4.26)$$

unde:

P_i^h - puterea activă cerută în nodul i la ora h , în [kW];

E_s - consumul total de energie activă din sistemul analizat, în [kWh] (consumul total de energie activă pentru ziua în care s-a înregistrat vârful de sarcină în sistemul analizat a fost de 27209,16 kWh);

N_{RP} - numărul total de noduri din sistemul analizat luate în considerare pentru clasificarea după puterea activă.

În continuare, s-a făcut gruparea nodurilor (după puterea activă) folosind una dintre metodele de grupare spațială descrise în capitolul 3 (metoda centrului de greutate - centroid method). Gruparea nodurilor s-a făcut atât după profilul graficelor de sarcină activă, cât și după energia consumată.

Pentru cele 34 de noduri, folosind metoda centrului de greutate, în urma procesului de grupare au fost obținute 3 grupe (C_{P1} , C_{P2} și C_{P3}), rezultatele procesului fiind prezentate în Fig. 4.19 și Tabelul 4.5.

Tabelul 4.5. Grupele de noduri de 20 kV

Grupa	Nr.noduri	$W_{\min}$ [kWh]	$W_{\max}$ [kWh]
C_{P1} - Small (S)	6	0	4500
C_{P2} - Medium (M)	14	4500	9000
C_{P3} - High (H)	14	9000	1200

Pentru fiecare grupă k , calculând media coeficienților p_i^h , se determină valorile coeficienților orari $m_{C_{Pk}}^h$ pentru reprezentatul mediu, cu relația:

$$m_{C_{Pk}}^h = \frac{\sum_{i=1}^{N_{C_{Pk}}} p_i^h}{N_{C_{Pk}}}; \quad h = 1, \dots, 24; \quad k = 1, \dots, N_{GP}, [\text{MW} / \text{MWh}] \quad (4.27)$$

unde:

N_{GP} – numărul de grupe rezultate în urma clasificării nodurilor după puterea activă ($N_{GP} = 3$);

$N_{C_{Pk}}$ – numărul de elemente (noduri) din fiecare grupă.

Coeficienții orari $m_{C_{Pk}}^h$ sînt coeficienții de transformare a energiei consumate de reprezentatul mediu al grupeii, în putere medie activă cerută de acesta. Valorile acestor coeficienți, pentru fiecare grupă în parte, sînt date în Tabelul 4.6.




Fig. 4.19. Diagrama procesului de grupare a nodurilor de 20 kV

Tabelul 4.6. Media și dispersia, m și σ , pentru cele trei grupe de noduri de 20 kV

Ora	C_{P1} (S)		C_{P2} (M)		C_{P3} (H)	
	m [kW/kWh]	σ [kW/kWh]	m [kW/kWh]	σ [kW/kWh]	m [kW/kWh]	σ [kW/kWh]
	$10^{-3} \times$		$10^{-3} \times$		$10^{-3} \times$	
1	0,5854	0,1616	0,9026	0,2624	1,3255	0,3025
2	0,5731	0,0599	0,7876	0,2477	1,1467	0,2751
3	0,4820	0,0679	0,7247	0,2284	1,0197	0,2247
4	0,4486	0,0641	0,6863	0,2072	0,9320	0,2161
5	0,4551	0,1153	0,6669	0,1829	0,8888	0,2033
6	0,4443	0,0869	0,6620	0,1753	0,9072	0,2090
7	0,4536	0,0717	0,7168	0,1965	0,9981	0,1723
8	0,4473	0,0656	0,8696	0,2074	1,2551	0,1955
9	0,4425	0,0425	1,0274	0,2646	1,4908	0,2610
10	0,4726	0,0473	1,0762	0,2769	1,6142	0,2526
11	0,5165	0,0654	1,1643	0,2813	1,7599	0,2778
12	0,5754	0,1033	1,2588	0,2458	1,8900	0,2796
13	0,6326	0,1163	1,3158	0,2091	1,9993	0,2584
14	0,7383	0,1575	1,3996	0,1800	2,1435	0,1832
15	0,7839	0,1165	1,4439	0,1563	2,2485	0,1374
16	0,7768	0,0975	1,4250	0,1507	2,2414	0,1168
17	0,7970	0,0704	1,4102	0,1354	2,1779	0,1530
18	0,7891	0,0575	1,3355	0,1344	2,0613	0,2116
19	0,8142	0,0417	1,2639	0,1395	1,9289	0,3018
20	0,8244	0,0607	1,2027	0,1832	1,8379	0,3385
21	0,8828	0,0993	1,2584	0,2564	1,8454	0,3118
22	0,9297	0,0789	1,2545	0,3382	1,7723	0,2987
23	0,8414	0,0916	1,1781	0,3432	1,6700	0,2763
24	0,7346	0,1143	1,0546	0,2851	1,5442	0,2516

Reprezentarea grafică a coeficienților $m_{C_{Pk}}^h$ ne conduce la graficele tip de sarcină corespunzătoare puterii active din Fig. 4.20, 4.21, 4.22, pentru nodurile de 20 kV din sistemul analizat. Cunoscând valorile coeficienților p_i^h ai reprezentanților din grupele determinate mai sus și valorile coeficienților $m_{C_{Pk}}^h$ ale reprezentantului mediu corespunzător acestora, în continuare, sînt determinate abaterile standard ale distribuției puterilor active corespunzătoare nodurilor din grupele analizate.

Abaterile standard sînt calculate cu relația:

$$\sigma_{C_{Pk}}^h = \sqrt{\frac{\sum_{i=1}^{N_{C_{Pk}}} (p_i^h - m_{C_{Pk}}^h)^2}{N_{C_{Pk}}}}; \quad h = 1, \dots, 24; \quad k = 1, \dots, N_{GP} \quad (4.28)$$




Fig. 4.20. Graficul tip de sarcină corespunzător nodurilor din C_{P1} (S)




Fig. 4.21. Graficul tip de sarcină corespunzător nodurilor din C_{P2} (M)




Fig. 4.22. Graficul tip de sarcină corespunzător nodurilor din C_{P3} (H)

Mărimile statistice din Tabelul 4.6 sînt folosite la fuzzificarea graficelor tip normalizate. Astfel, trapezul fuzzy normalizat se determină cu o relație de tipul [Cârțină 04/3]:

$$[x_1, x_2, x_3, x_4] = [m - 1,28\sigma, m - \sigma, m + \sigma, m + 1,28\sigma] \quad (4.29)$$

Pentru estimarea sarcinii fuzzy în nodurile sistemului analizat, la vîrf de sarcină, se aplică metoda corelației fuzzy pentru fiecare grupă de noduri în parte. Sarcina la ora vîrfului de sarcină corespunzătoare profilului de referință, în raport cu care se studiază corelarea, este trapezul fuzzy obținut cu relația (4.29) care se înmulțește cu energia activă totală consumată în sistemul analizat.

Trapezele fuzzy pentru puterile active din nodurile rețelei de 20 kV obținute cu metoda corelației fuzzy îmbunătățită cu tehnicile de clusterizare sînt prezentate în Tabelul 4.7.

În Fig. 4.23 sînt reprezentate erorile de estimare obținute aplicînd metoda corelației fuzzy simplă și metoda corelației fuzzy îmbunătățită cu tehnicile de grupare spațială.

Această metodă fuzzy de estimare a puterilor la vîrfului de sarcină se bazează în primul rînd pe îmbunătățirea procesului de fuzzificare pentru graficele tip de sarcină normalizate.

Se constată că, în cazul metodei corelațiilor fuzzy îmbunătățită cu tehnici de grupare spațială diferențele valorile crisp și cele măsurate sînt mult mai reduse decît în cazul metodei corelației fuzzy.




Fig. 4.23. Erorile de estimare a sarcinii din noduri, la ora vîrfului de sarcină

■ Metoda corelației fuzzy

□ Metoda corelației fuzzy îmbunătățită cu tehnici de grupare spațială

Tabelul 4.7. Rezultatele obținute folosind metoda corelației fuzzy îmbunătățită cu tehnici de grupare spațială

PT	Valorile "Breaking Points"				Valorile crisp	Valorile măsurate	Eroarea
	P1 [kW]	P2 [kW]	P3 [kW]	P4 [kW]	P _f [kW]	P _m [kW]	Er _p [%]
1	195,80	205,68	276,20	286,07	240,94	240,50	0,18
2	173,45	182,74	249,05	258,34	215,89	216,30	-0,19
3	231,83	249,85	378,58	396,60	314,22	311,10	1,00
4	274,30	307,73	546,52	579,95	427,13	436,00	-2,03
5	381,46	390,38	454,10	463,02	422,24	410,70	2,81
6	340,11	354,33	455,85	470,06	405,09	420,30	-3,62
7	573,87	581,93	639,52	647,59	610,73	600,60	1,69
8	568,61	580,32	664,02	675,74	622,17	617,70	0,72
9	531,74	539,70	596,49	604,44	568,09	561,20	1,23
10	153,18	164,26	243,41	254,50	203,84	208,70	-2,33
11	583,05	592,47	659,81	669,24	626,14	617,00	1,48
12	544,65	553,80	619,17	628,33	586,49	588,10	-0,27
13	413,68	412,39	403,21	401,92	407,80	404,90	0,72
14	291,34	306,07	411,27	426,00	358,67	357,20	0,41
15	318,15	327,94	397,88	407,67	362,91	360,40	0,70
16	269,86	287,95	417,15	435,24	352,55	365,60	-3,57
17	462,09	479,93	607,39	625,23	543,66	545,70	-0,37
18	206,83	219,00	305,93	318,10	262,46	254,90	2,97
19	164,88	170,97	214,49	220,58	192,73	191,30	0,75
20	142,13	146,90	180,98	185,75	163,94	168,10	-2,48
21	633,94	640,01	683,39	689,46	661,70	667,50	-0,87
22	413,11	416,59	441,41	444,88	429,00	421,40	1,80
23	362,65	378,61	492,59	508,55	435,60	440,40	-1,09
24	565,11	577,08	662,63	674,61	619,86	637,00	-2,69
25	365,09	382,70	508,50	526,11	445,60	452,30	-1,48
26	560,77	573,11	661,26	673,60	617,19	623,70	-1,04
27	397,39	399,84	417,33	419,77	408,58	402,20	1,59
28	607,67	623,46	736,19	751,97	679,82	671,80	1,19
29	599,26	605,78	652,36	658,88	629,07	634,10	-0,79
30	535,65	548,70	641,90	654,95	595,30	594,20	0,19
31	386,32	389,48	412,01	415,17	400,74	388,10	3,26
32	292,78	300,98	359,54	367,74	330,26	329,80	0,14
33	495,68	507,51	592,01	603,84	549,76	571,00	-3,72
34	632,65	637,54	672,48	677,37	655,01	635,40	3,09

4.4. Analiza regimurilor rețelelor de transport și distribuție cu modele fuzzy

Evaluarea regimurilor de funcționare a rețelelor electrice constituie o preocupare importantă în activitatea de exploatare și de planificare a dezvoltării rețelelor.

În mod uzual, planificarea regimurilor de funcționare și studiile de dezvoltare a oricărei infrastructuri, energetică sau de oricare alt tip, folosesc rezultatele estimărilor efectuate, pe termen scurt sau pe termen lung. Odată ce s-a intrat în posesia datelor estimate se creează scenarii care să cuprindă aceste informații și, pe baza cărora se evaluează o serie de regimuri de funcționare reprezentative. Acest tip de analiză, evident avînd la bază o procedură de selecție corespunzătoare, are ca neajuns faptul că inspectează numai o parte din toate posibilitățile de combinare a sarcinilor nodale, aceasta fiind în esență o analiză de tip determinist.

În ultimii ani se manifestă un interes tot mai mare pentru aplicarea conceptelor teoriei mulțimilor fuzzy în diverse studii privind exploatarea optimă și planificarea sistemelor electroenergetice. În aceste condiții, pornind de la estimarea puterilor nodale folosind metode fuzzy, se poate reflecta mai realist comportarea unei rețele electrice în diferite regimuri de încărcare.

4.4.1. Modelarea fuzzy în analiza regimurilor rețelelor de transport

În cadrul acestui paragraf se prezintă posibilitățile de aplicare a modelelor fuzzy de sarcină la analiza regimurilor rețelei de transport de 400/220 kV. Modelele fuzzy s-au stabilit pornind de la datele regimurilor de vîrf de sarcină iarnă (16.01.2002), obținute prin măsurători de către sucursalele de distribuție a energiei electrice din Moldova și prezentate în subcapitolul 4.3.1.

Sistemul în studiu reprezintă zona de nord a rețelei de transport din Moldova, împreună cu rețeaua de distribuție de 110 kV, avînd următoarele caracteristici [Cârjină 03/3]:

- 121 de noduri, la treptele de tensiune de 400 kV, 220 kV și 110 kV;
- 152 laturi, reprezentînd linii de 220 kV și 110 kV și autotransformatoare 400/220 kV și 220/110 kV;
- 3 noduri de frontieră cu sistemul extern: un nod de 400 kV, numerotat 24 și două noduri de 220 kV, numerotate 77 și 83.
- nodul 24 este nod de echilibru, avînd tensiunea fixată la valoarea de 410 kV.

Schema redusă a rețelei de transport analizate este prezentată în Anexa 1.

Analiza regimurilor permanente de funcționare la vîrf de sarcină iarna (VSI) folosind modele fuzzy pentru sarcinile nodale are ca punct de plecare regimurile de referință pentru iarnă, stabilite pe baza următoarelor ipoteze de calcul:

1. Schema de funcționare a rețelei de transport este schema normală, valabilă pentru iarna anului 2002.
2. Toate autotransformatoarele funcționează pe plotul 13, excepție fac AT 220/110 kV, conectat între nodurile 77 – 160 și AT 400/220 kV, conectat între nodurile 24 – 12 ce funcționează pe plotul 16.
3. Puterile consumate la nodurile de 110 kV obținute prin măsurători de către sucursalele Electrica din Moldova corespund vîrfului de sarcină (VSI) înregistrat la data de 16.01.2002. Aceste sarcini determină încărcarea maximă a rețelei în ziua respectivă. Consumurile nodurilor care nu fac parte din schema operativă normală au fost repartizate în nodurile vecine care sînt incluse în această schemă.

Avînd în vedere structura rețelei în studiu și ipotezele de calcul menționate mai sus pentru regimurile de bază, în continuare se prezintă modul de utilizare a modelelor fuzzy de sarcină în analiza regimului permanent a rețelei de 400/220/110 kV din zona Moldovei.

Pentru puterile consumate la VSI în nodurile de 110 kV aparținînd filialelor Electrica se vor folosi trapezele fuzzy, determinate cu ajutorul metodei corelației fuzzy din subcapitolul 4.3.1. La fel ca în regimurile de bază, consumurile din nodurile care nu fac parte din schema operativă normală au fost repartizate în nodurile vecine care sînt incluse în schemă.

La calculul regimului permanent cu sarcini fuzzy este necesar calculul de regim în toate cele patru puncte caracteristice (x_1 , x_2 , x_3 și x_4), astfel încît toate variabilele de stare (tensiuni, circulații de puteri, pierderi de putere etc.) se obțin ca variabile fuzzy, care ulterior sînt supuse operației de defuzzificare. În toate regimurile calculate, ipotezele de calcul 1 ... 3 au fost menținute nemodificate.

Analiza regimului permanent de funcționare are drept scop furnizarea de informații privind regimul rețelei de transport la vîrf de sarcină (VSI) pentru funcționarea optimă din punct de vedere economic, pentru studiile de planificare a dezvoltării rețelelor, folosind rezultatele estimărilor efectuate cu metoda corelației fuzzy pentru sarcinile din nodurile de 110 kV aparținînd sucursalele Electrica.

Analiza a pus în evidență faptul că folosirea trapezelor fuzzy obținute cu ajutorul metodei corelației fuzzy pentru puterile nodale conduce la rezultate acoperitoare în ceea ce privește estimarea stării rețelei de transport la VSI (determinarea nivelului de tensiune în noduri, a circulațiilor și pierderilor de putere etc.). În acest sens, un interes deosebit îl prezintă rezultatele privind circulațiile de puteri prin autotransformatoarele din stațiile de 220/110 kV, pe partea de 110 kV, tensiunile pe barele de 110 kV ale acestor stații, pierderile totale de putere pe liniile și transformatoarele rețelei de 400/220 kV analizată.

Tabelul 4.8. Circulațiile de putere activă pe partea de 110kV a AT
din stațiile de 220/110kV

AT	$x_1 = x_2$ [MW]	x_3 [MW]	x_4 [MW]	Crisp [MW]	P_b [MW]
78-107	-9,09	-3,66	-1,76	-4,83	-5,30
81-116	1,50	6,79	7,84	5,37	6,77
80-132	40,83	44,28	45,95	43,68	45,02
25-147	-3,11	0,44	6,96	-1,42	-0,79
12-158	13,08	14,79	31,55	19,8	14,58
77-160	13,44	21,49	37,64	24,18	19,68
82-186	41,82	42,71	43,11	42,54	48,27
83-915	25,86	36,80	39,71	34,14	37,05
950-923	18,92	18,89	18,09	18,63	18,60

Tabelul 4.9. Circulațiile de putere reactivă pe partea de 110kV a AT
din stațiile de 220/110kV

AT	$x_1 = x_2$ [MVar]	x_3 [MVar]	x_4 [MVar]	Crisp [MVar]	Q_b [MVar]
78-107	0,28	-4,02	-4,08	-2,60	-4,08
81-116	2,92	-15,66	-15,56	-9,43	-14,94
80-132	0,14	-8,87	-8,63	-5,78	-7,51
25-147	13,59	5,76	5,71	8,34	4,51
12-158	-23,55	-34,48	-30,48	-29,50	-33,36
77-160	72,67	64,41	66,15	67,74	63,49
82-186	6,87	18,21	19,45	14,84	20,08
83-915	-11,13	-20,71	-20,55	-16,71	-18,85
950-923	15,36	20,98	21,60	19,31	22,34

Tabelul 4.10. Valorile tensiunilor pe partea de 110 kV a AT
din stațiile de 220/110kV

AT	$x_1 = x_2$ [kV]	x_3 [kV]	x_4 [kV]	Crisp [kV]	U_b [kV]
78-107	119,48	122,05	121,65	121,06	121,44
81-116	120,08	125,70	125,33	123,70	125,20
80-132	119,42	124,45	124,11	122,66	123,98
25-147	118,27	122,24	121,88	120,42	122,01
12-158	119,45	123,57	123,11	122,40	123,40
77-160	119,55	123,63	123,20	122,12	123,45
82-186	119,01	121,65	121,12	120,56	120,89
83-915	119,91	122,24	120,76	121,19	121,33
950-923	118,08	121,05	120,61	119,91	120,51

Tabelul 4.11. Pierderile de putere pe liniile și transformatoarele din rețeaua de 400/220/110 kV

Mărimi de stare	$x_1 = x_2$	x_3	x_4	Crisp	Regim de referință
ΔP_L [MW]	6,03	6,75	6,99	6,59	6,96
ΔP_{Tr} [MW]	0,22	0,24	0,29	0,25	0,24
ΔQ_L [MVar]	18,47	21,19	22,01	20,55	22,29
ΔQ_{Tr} [MVar]	9,19	10,00	12,40	10,53	9,86
ΔQ_{Lcap} [MVar]	233,25	246,87	247,28	242,46	243,31

În Tabelele 4.8, 4.9, 4.10 și 4.11 sînt prezentate rezultatele circulațiilor de putere activă și reactivă pe partea de 110 kV a AT din stațiile de 220/110 kV, tensiunea pe barele de 110 kV ale acestor stații și pierderile totale de putere activă și reactivă în liniile și autotransformatoarele rețelei analizate corespunzătoare regimului de referință (coloanele P_r , Q_r și U_r) și celor 4 puncte caracteristice la VSI. Regimul de referință a fost calculat utilizînd valorile măsurate ale puterilor active și reactive din nodurile de 110 kV.

4.4.2. Utilizarea modelelor fuzzy în analiza regimurilor rețelelor de distribuție

În cele ce urmează se prezintă analiza regimului permanent de funcționare la vîrf de sarcină a unei rețele electrice distribuție de 20 kV, pornind de la două modele fuzzy: sarcini corelate și sarcini necorelate. Structura rețelei cuprinde 34 de posturi de transformare, echipate cu transformatoare de 400, 630 și 1000 kVA și 34 de linii.

Schema rețelei de distribuție analizate este dată în Anexa 2.

Puterile de sarcină pentru care se folosesc modelele fuzzy, sînt date pe partea de joasă tensiune a posturilor de transformare. Posturile de transformare alimentează consumatori preponderent rezidențiali.

Modelul fuzzy cu sarcini necorelate are la bază modelul cu sarcini necorelate descris în subcapitolul 4.2.1 iar modelul fuzzy cu sarcini corelate are la bază modelul corelației fuzzy, descris în paragraful 4.3.1.

Efectuarea calcului regimului permanent se face în fiecare din punctele caracteristice x_1 , x_2 , x_3 și x_4 . Ca urmare, toate variabilele de stare, tensiuni nodale, circulații de puteri, pierderi etc vor fi determinate ca numere fuzzy.

Variabilele fuzzy primare, K_p și $\cos\phi$, necesare determinării puterilor active și reactive din PT cu ajutorul modelului fuzzy cu sarcini necorelate sînt date Tabelul 4.12. Valorile "breaking points" corespunzătoare nivelelor lingvistice din cadrul tabelului de mai sus sînt precizate în Tabelul 3.3 din cadrul paragrafului 3.2.3.

Tabelul 4.12. Nivelele lingvistice pentru variabilele K_p și $\cos\varphi$ corepunzătoare modelului fuzzy cu sarcini necorelate

PT	S_n [kVA]	Nr. trafo	K_p [%]	K_p (fuzzy)	$\cos\varphi$ (fuzzy)
1	400	1	0,65	H	H
2	400	1	0,59	M	H
3	630	1	0,54	M	H
4	630	1	0,75	H	H
5	630	1	0,71	H	H
6	630	1	0,73	H	H
7	1000	1	0,65	H	H
8	1000	1	0,67	H	H
9	1000	1	0,61	H	H
10	400	1	0,57	M	H
11	1000	1	0,67	H	H
12	1000	1	0,64	H	H
13	630	1	0,70	H	H
14	630	1	0,62	H	H
15	630	1	0,62	H	H
16	630	1	0,63	H	H
17	1000	1	0,59	M	H
18	400	1	0,69	H	H
19	400	1	0,52	M	H
20	400	1	0,46	H	H
21	1000	1	0,73	H	H
22	630	1	0,73	H	H
23	630	1	0,76	H	H
24	1000	1	0,69	H	H
25	630	1	0,78	H	H
26	1000	1	0,68	H	H
27	630	1	0,69	H	H
28	1000	1	0,73	H	H
29	1000	1	0,69	H	H
30	1000	1	0,65	H	H
31	630	1	0,67	H	H
32	630	1	0,57	M	H
33	1000	1	0,62	H	H
34	1000	1	0,69	H	H

Rezultatele obținute în urma calculelor de regim permanent, utilizând cele două modele fuzzy de sarcină sînt date în Tabelele 4.13 și 4.14. Semnificația notațiilor din aceste tabele este următoarea:

- P_s, Q_s – puterea activă, respectiv, reactivă injectată în nodul de echilibru;
- P_d, Q_d – puterea activă, respectiv, reactivă totală cerută de consumatori;

- $\Delta P_T, \Delta Q_T$ – pierderi totale de putere activă, respectiv, reactivă, în rețeaua de distribuție;
- $\Delta P_L, \Delta Q_L$ – pierderi totale de putere activă, respectiv, reactivă, în linii;
- $\Delta P_{Tr}, \Delta Q_{Tr}$ – pierderi totale de putere activă, respectiv, reactivă, în transformatoare;
- ΔQ_C – aportul capacitiv al liniilor.

Pentru a interpreta corect rezultatele sintetizate în Tabelele 4.13 și 4.14, în Fig. 4.24 și 4.25 sînt reprezentate funcțiile de apartenență pentru pierderile totale de putere activă, respectiv, reactivă obținute cu cele două modele de sarcină.

Tabelul 4.13. Mărimile de stare pentru modelul fuzzy cu sarcini corelate

Mărimi de stare	"Breaking points" pentru modelul fuzzy cu sarcini corelate				
	x_1	x_2	x_3	x_4	Crisp
P_s [kW]	14081,67	14856,06	15397,45	16397,45	15183,16
Q_s [kVAr]	9321,84	8562,00	7324,74	6102,63	7827,80
ΔP_L [kW]	86,50	89,30	89,60	91,80	89,30
ΔP_{Tr} [kW]	186,30	190,50	191,10	194,80	190,68
ΔP_T [kW]	272,78	279,76	280,70	286,65	279,97
ΔQ_L [kVAr]	57,70	59,60	59,80	61,30	59,60
ΔQ_{Tr} [kVAr]	1208,60	1228,00	1231,40	1249,10	1229,28
ΔQ_T [kVAr]	1266,30	1287,60	1291,20	1310,40	1288,88
Q_{CL} [kVAr]	502,28	502,25	502,23	502,21	502,24

Tabelul 4.14. Mărimile de stare pentru modelul fuzzy cu sarcini necorelate

Mărimi de stare	"Breaking points" pentru modelul fuzzy cu sarcini necorelate				
	x_1	x_2	x_3	x_4	Crisp
P_s [kW]	11589,35	14155,83	16832,85	19622,12	15550,04
Q_s [kVAr]	6984,76	7828,62	8441,97	8761,38	8004,18
ΔP_L [kW]	55,70	79,10	106,80	138,70	95,08
ΔP_{Tr} [kW]	139,50	174,90	216,80	265,20	199,10
ΔP_T [kW]	195,15	254,03	323,65	403,92	294,19
ΔQ_L [kVAr]	37,10	52,80	71,20	92,50	63,40
ΔQ_{Tr} [kVAr]	994,10	1157,60	1351,50	1575,50	1269,68
ΔQ_T [kVAr]	1031,20	1210,40	1422,70	1668,00	1333,08
Q_{CL} [kVAr]	503,24	502,53	501,82	501,14	502,18




Fig. 4.24. Funcțiile de apartenență pentru pierderile totale de putere activă




Fig. 4.25. Funcțiile de apartenență pentru pierderile totale de putere reactivă

După cum se observă, rezultatele obținute cu modelul sarcinilor corelate sînt mult diferite în raport cu cazul necorelației sarcinilor.

Bibliografie

- [Alexandrescu 00] Alexandrescu, V., Cârțină, Gh., Bîrlădeanu, E., Bonciu, Cl., Grigoraș, Tehnici fuzzy în analiza rețelelor electrice de distribuție de medie tensiune, Simpozionul Național de Rețele Electrice, 2000, Iași, Vol. II, pp. 284 – 289.
- [Alexandrescu 01] Alexandrescu, V., Cârțină, Gh., Grigoraș, Gh., Popa, C., Ciutea, I., Using Fuzzy Load Models in Distribution Network Monitoring and Control, Proc. of the Conference Modeling and Optimization in the Machines Building Field, 2001, Bacău, Vol. 1, pp. 236 – 241.
- [Broadwater 97] Broadwater, R. P., Sargent, Al., Yarali, A., Shaalan, H., Nazarko, J., Estimating Substation Peaks from Load Research Data, IEEE Trans. on Power Delivery, 1997, Vol.12, No. 1, pp. 451 - 456.
- [Cârțină 00/1] Cârțină, Gh., Alexandrescu, V., Grigoraș, Gh., Peak load estimation in distribution networks, Proc. of the 23rd International Conference on Fundamentals of Electrotechnics and Circuit Theory, SPETO'00, 2000, Gliwice-Ustron, Polonia, pp.423-426.
- [Cârțină 00/2] Cârțină, Gh., Alexandrescu, V., Bîrlădeanu, E., Grigoraș, Gh., Calcule utilizând tehnici fuzzy în rețeaua de 110 kV a SDEE Galați vizînd simularea sarcinii, calculul regimurilor și optimizarea funcționării rețelei, Contract de cercetare pentru SDEE Galați, Nr. 853/2000.
- [Cârțină 01/1] Cârțină, Gh., Grigoraș, Gh., Inteligența artificială. Optimizări în energetică, Casa de Editură VENUS, Iași, 2001.
- [Cârțină 01/2] Cârțină, Gh., Grigoraș, Gh., Active and Reactive Power Correlation in Fuzzy Modeling, Buletinul Științific al Univ. "Politehnica" din Timișoara, 2001, Seria Energetica, Fascicola 1-2, pp. 69 - 72.
- [Cârțină 02/1] Cârțină, Gh., Grigoraș, Gh., Tehnici moderne de optimizare. Aplicații în energetică, Casa de Editură VENUS, Iași, 2002.
- [Cârțină 02/2] Cârțină, Gh., Alexandrescu, V., Grigoraș, Gh., Application of Powers Correlation in Fuzzy Modeling, Bul. I.P.Iași, 2002, Tomul XLVIII (LII), Fasc. 5A, pp. 297 – 302.
- [Cârțină 02/3] Cârțină, Gh., Grigoraș, Gh., Moshe, M., Using of the Power Correlation in Distribution Networks Planning, Bul. I.P.Iași, 2002, Fascicola 1 – 2, pp. 149 - 157.
- [Cârțină 02/4] Cârțină, Gh., Grigoraș, Gh., Fuzzy Modeling in Distribution Systems, Proc. of the 25th International Conference on Fundamentals of Electrotechnics and Circuit Theory, IC-

CAPITOLUL 5

OPTIMIZĂRI MULTICRITERIALE ÎN ELECTROENERGETICĂ

5.1. Aspecte generale privind optimizarea multicriterială

Marea majoritate a problemelor practice de optimizare, în special cele de planificare și exploatare a sistemelor energetice, sînt probleme în care se urmărește îmbunătățirea concomitentă a mai multor obiective (minimizarea costurilor, minimizarea impactului asupra mediului, maximizarea fiabilității etc).

În problemele de optimizare multiobiectiv, de cele mai multe ori obiectivele urmărite sînt non-comensurabile și nu pot fi combinate ușor într-o singură funcție obiectiv. Mai mult decît atît, adesea soluțiile sînt conflictuale și orice îmbunătățire a unui obiectiv se obține în detrimentul altui/altor obiective. În aceste situații se impune intervenția unui decident, Decision-Making (DM), pentru a realiza un compromis între soluțiile posibile. Acesta trebuie să aleagă o soluție de compromis dintre soluțiile non-inferioare.

În unele cazuri este posibilă convertirea în probleme cu un singur obiectiv, înainte de a se aplica un algoritm de optimizare. Această conversie poate fi făcută foarte simplu prin stabilirea, de la început, a preferinței pentru fiecare obiectiv. Astfel, DM poate defini o singură funcție obiectiv făcînd suma scalară ponderată a funcțiilor obiectiv individuale. În acest fel se convertește o problemă multiobiectiv într-o problemă cu un singur obiectiv și se poate spune că problemele de optimizare cu obiectiv unic reprezintă o subclasă a problemelor de optimizare multiobiectiv.

Punerea la punct a unor metode eficiente de rezolvare a problemelor multiobiectiv, fără a apela la conversia în probleme cu obiectiv unic și fără stabilirea preferințelor pentru fiecare obiectiv reprezintă o sarcină importantă a activităților actuale de cercetare.

Aceast interes poate fi încurajat prin considerarea a doi factori, care pot contribui la rezolvarea problemelor respective [Lampinen 00]:

- **Optimizarea Pareto** care nu necesită nici o preferință **a priori** în cazul obiectivelor aflate în conflict.
- **Optimizarea evolutivă** se dovedește a fi un instrument potențial pentru rezolvarea problemelor de optimizare Pareto.

Pentru rezolvarea problemelor multiobiectiv pînă în prezent s-au folosit mai multe metode. Ca și în cazul problemelor de optimizare cu obiectiv unic, aceste metode pot fi clasificate în: metode enumerative, deterministe și stochastice. Fiecare din aceste metode are propriile avantaje și limite de folosire.

Metodele enumerative sînt mai puțin folosite și mai puțin eficiente. Aceste metode pot fi folosite numai în cazul problemelor cu spațiu de căutare a soluțiilor discret, iar evaluarea tuturor soluțiilor se poate face doar dacă numărul acestora este redus. Problemele continue pot fi rezolvate de asemenea cu ajutorul acestor metode, dar este necesară discretizarea spațiului de căutare și respectarea cerinței precedente.

Folosirea eficientă a **metodelor deterministe** este limitată la o mulțime redusă de probleme de optimizare multiobiectiv. Folosirea acestor metode este determinată de ipotezele care se fac cu privire la proprietățile funcției obiectiv. Dacă funcția obiectiv nu reușește să satisfacă aceste ipoteze, metodele deterministe nu pot fi folosite. Ipotezele pe care se bazează aceste metode sînt [Lampinen 00], [Cârțină 03/5]:

- problema este liniară;
- problema este convexă;
- spațiul de căutare este redus;
- spațiul de căutare este continuu;
- nu există legături neliniare între parametri;
- derivatele sau alte informații suplimentare corespunzătoare funcției obiectiv sînt disponibile;
- problema este disponibilă în formă analitică etc.

În cazul în care ipotezele de mai sus nu pot fi considerate, pentru rezolvarea problemelor multiobiectiv sînt utilizate **metodele stochastice**. Cea mai simplă metodă este metoda Monte Carlo. O metodă de căutare stohastică solicită numai valorile funcțiilor obiectiv. În cazul acestor metode nu se face nici o ipoteză și nu se folosește nici o informație suplimentară cu privire la funcția obiectiv.

Inginerul economist Vilfredo Pareto, în anul 1886, face una dintre cele mai importante descoperiri din domeniul optimizării multiobiectiv și anume:

Soluțiile multicriteriale pot fi în mod parțial ordonate, fără stabilirea unei preferințe a priori.

Soluțiile optimale corespunzătoare unei probleme multiobiectiv, definite prin aplicarea principiului Pareto, sînt în mod curent numite **soluții optimale Pareto** datorită motivului expus anterior.

În cazul obiectivelor conflictuale, soluțiile optimale Pareto reprezintă mai degrabă o clasă de soluții, formînd o suprafață în spațiul funcției obiectiv. Această suprafață este în mod obișnuit denumită ca fiind un **Pareto-front**.

Deciziile pot fi luate aplicînd una din următoarele abordări [Lampinen 00]:

- **Stabilirea a priori a preferinței:** Decidentul, Decision-Making (DM), stabilește ponderea fiecărei funcții obiectiv individuale înainte de rularea algoritmului de optimizare. În practică, aceasta înseamnă că DM combină funcțiile obiectiv individuale într-o funcție scalară de cost. Această abordare convertește în mod eficient o problemă multiobiectiv într-o problemă cu obiectiv unic.
- **Stabilirea progresivă a preferinței:** DM influențează programul de optimizare în timpul procesului de optimizare interactiv. Sistemul asigură o îmbunătățire a soluțiilor și permite DM să stabilească dacă să modifice sau nu ponderea funcțiilor obiectiv individuale.
- **Stabilirea posteriori a preferinței:** În acest caz nu se specifică nici o pondere pentru funcțiile obiectiv individuale înainte sau în timpul procesului de optimizare. Algoritmul de optimizare indică o mulțime de soluții din care DM alege soluția ce va fi utilizată.

În mod curent, în legătură cu utilizarea algoritmilor evolutivi, există două abordări diferite în definirea adecvată a unei probleme multiobiectiv, în cazul obiectivelor conflictuale [Lampinen 00]:

- **Suma ponderată a funcțiilor obiectiv:** Potrivit acestei abordări problema multiobiectiv este convertită într-o problemă cu obiectiv unic a cărei funcție obiectiv este formată din suma ponderată a funcțiilor obiectiv individuale. Acest lucru coincide cu stabilirea a priori a preferinței.
- **Optimizarea Pareto:** În acest caz problema multiobiectiv se rezolvă aplicînd optimizarea Pareto. DM-ul alege soluția din mulțimea soluțiilor optimale Pareto. Aceasta coincide cu o stabilire posteriori a preferinței.

Conceptul de **Optim Pareto**, introdus de inginerul economist Vilfredo Pareto în cadrul optimizării multiobiectiv, poate fi caracterizată în felul următor:

”... termenul *optimizare* dintr-o problemă multiobiectiv de luare a deciziilor se referă la o soluție aproximativă pentru care îmbunătățirea unui obiectiv se poate face numai în detrimentul celorlalte obiective”.

Problemele cu obiective multiple nu au o soluție optimală unică, dar au o mulțime de soluții optimale Pareto. Mulțimea soluțiilor optimale Pareto poate fi caracterizată de **Pareto-front** ce reprezintă o hipersuprafață în spațiul funcției obiectiv, în care sînt localizate punctele optimale Pareto.

În problemele de optimizare multiobiectiv din energetică se încearcă să se îmbunătățească oarecum concomitent fiecare dintre obiectivele considerate, respectîndu-se totodată restricțiile care intervin. În optimizarea dezvoltării/modernizării rețelelor electrice, de exemplu, pot fi considerate trei criterii importante: de cost, de fiabilitate a distribuției și de impact asupra mediului. În principiu se urmărește minimizarea costului economic și al impactului asupra mediului, precum și maximizarea fiabilității rețelelor respective. Problema este una de optimizare multicriterială cu restricții. În contrast cu metodele de optimizare tradiționale, de regulă uniobiectiv, în ultima vreme, metodele de optimizare multiobiectiv se impun din ce în ce mai mult datorită avantajelor lor. Fundamental în optimizarea multiobiectiv este conceptul Pareto (cunoscut ca soluția noninferioară). Presupunînd că DM urmărește scopuri imprecise sau de tip fuzzy, pentru fiecare obiectiv acestea pot fi cuantificate prin definirea unor funcții de apartenență corespunzătoare. În rezolvarea unei asemenea probleme pot fi folosite următoarele metode [Rheinert 97]:

- definirea unei sume de funcții scalare ponderate;
- optimizarea după unul din criterii, tratînd pe celelalte ca restricții etc.
- transformarea într-o problemă cu un singur obiectiv, prin tehnici fuzzy.

Referitor la folosirea tehnicilor fuzzy, aspectul cel mai important este, definirea funcțiilor de apartenență corespunzătoare fiecărui criteriu, pe baza experienței decidentului, DM. Scopul DM este găsirea unui compromis între toate soluțiile. Pentru aceasta este necesar să se estimeze mai întîi valorile maximă/minimă și forma corespunzătoare pentru fiecare funcție de apartenență, pe baza experienței experților.

5.2. Criterii de comparare a variantelor

În planificarea dezvoltării instalațiilor de distribuție pot fi întâlnite mai multe criterii [Romanello 95, Trocme 96]: economic, siguranța în alimentare, impactul asupra mediului etc.

Criteriul economic, discutat pe larg în literatura de specialitate, are în vedere:

- costul investiției (linii aeriene, cabluri, echipamente de comutație, echipamente de automatizare etc).
- costul pierderilor termice;
- costul defectărilor etc [Romanello 95].

În cele ce urmează ne vom referi pe rând la celelalte criterii și anume: siguranța în alimentarea consumatorilor și impactul asupra mediului ambiant.

5.2.1. Siguranța în alimentare

Siguranța în alimentarea cu energie electrică trebuie să răspundă cerințelor corespunzătoare categoriilor consumatorilor alimentați și să asigure continuitatea în alimentare conform condițiilor contractuale stabilite.

Obiectivul clasic al planificării dezvoltării rețelelor electrice este planificarea investiției, pentru a asigura o alimentare economică și fiabilă.

Fiabilitatea face parte din siguranța în funcționare a unui sistem, care constă în aptitudinea de a îndeplini o anumită sarcină. Conceptul de siguranță în funcționare grupează 4 noțiuni distincte: fiabilitatea, disponibilitatea, mentenabilitatea și securitatea [Desmas 92]:

- **Fiabilitatea** – se măsoară prin probabilitatea ca o entitate să-și îndeplinească misiunea pe durata unui interval de timp dat.
- **Disponibilitatea** – se măsoară prin probabilitatea ca o entitate să-și îndeplinească misiunea la un moment dat. Pentru un sistem nereparabil, cele două noțiuni sînt identice.
- **Mentenabilitatea** – este măsurată prin probabilitatea, pe un interval de timp dat, de a pune în stare de funcționare o entitate care este defectă.
- **Securitatea** – se măsoară prin probabilitatea ca o entitate să evite apariția, în anumite condiții date, a evenimentelor critice sau catastrofale.

Fiabilitatea alimentării consumatorilor constituie unul dintre cei mai importanți indicatori de calitate. Fiabilitatea rețelelor electrice este determinată de fiabilitatea componentelor, de fiabilitatea arhitecturii acestora, de sarcina electrică. În situații “ideale” rețeaua electrică trebuie să aibă o fiabilitate “suportabilă” de consumatori. Studiile de fiabilitate necesită informații despre istoricul comportării componentelor, despre consecințele economice ale defectării acestora etc.

În Fig. 5.1 sînt prezentate metodele pentru aplicarea criteriului de siguranță în alimentare, la planificarea rețelelor de distribuție [Backes 97].




Fig.5.1. Metode pentru aplicarea criteriului de siguranță în planificarea rețelelor electrice

Criteriile de fiabilitate utilizate în energetică pot fi clasificate după mai multe considerente în: criterii deterministe/probabilistice, tehnice/economice etc. Alegerea criteriului depinde în mare măsură de cei care întocmesc studiul de proiectare/dezvoltare, de cunoștințele și experiența lor. Criteriile de proiectare/dezvoltare a rețelelor electrice sînt, în general, deterministe, iar criteriul $(n - 1)$ este aproape universal, completat uneori cu criterii specifice, mai severe.

La nivel de client, fiabilitatea este percepută prin numărul de întreruperi (lungi și scurte) pe an, durata anuală a întreruperilor, costul aferent al acestora etc.

Pentru a atinge a diminua numărul și durata întreruperilor la nivel de consumator, EdF a decis să acționeze pe trei direcții [Carer 97]:

- restructurarea rețelelor MT, pentru micșorarea lungimilor axelor și mărirea numărului punctelor de alimenare;
- creșterea nivelului de automatizare a rețelelor MT pentru izolarea mai rapidă a porțiunilor defecte și diminuarea duratei de întrerupere;
- creșterea fiabilității lucrărilor și a materialelor prin:
 - înlocuirea echipamentelor vechi;
 - extinderea rețelei subterane MT în mediul rural;

- creșterea performanțelor echipamentelor etc.

5.2.1.1. Metodologia UNIPED

Indicatorii de fiabilitate

UNIPED recomandă următorii indicatori de fiabilitate pentru estimarea siguranței în funcționarea sistemului de distribuție de MT și JT [UNIPED 95]:

- **Durata medie de întrerupere a sistemului – SAIDI** (System Average Interruption Duration Index) sau numărul mediu de minute de nealimentare într-un sistem, [minute/an];
- **Frecvența medie de întrerupere – CAIFI** (Customer Average Interruption Frequency Index) sau numărul mediu de întreruperi a unui consumator, [întreruperi/an];
- **Durata medie de întrerupere a unui consumator – CAIDI** (Customer Average Interruption Duration Index) sau durata medie de întrerupere a alimentării unui consumator, [minute/întrerupere].

Indicatorii de fiabilitate ai RD de MT

Dacă nu există informații precise cu privire la numărul consumatorilor rămași fără alimentare cu energie electrică în urma avariilor sau a întreruperilor planificate ale diverselor componente a RD de MT, calculul după definițiile de mai sus ale indicatorilor de siguranță în alimentarea consumatorilor nu este posibil de realizat în mod practic. Majoritatea consumatorilor fiind consumatori de JT și presupunând că numărul consumatorilor alimentați de un transformator este proporțional cu puterea instalată a acestuia, calculul acestor indicatori se poate face însă pe baza cunoașterii puterii instalate a transformatoarelor de distribuție întrerupte în timpul avariilor sau întreruperilor planificate din rețeaua de distribuție de MT analizată. În această situație, relațiile de definiție ale indicatorilor de fiabilitate sînt următoarele:

$$SAIDI = \frac{\sum_{i=1}^n (S_i \cdot T_i)}{S_I}; \quad CAIFI = \frac{\sum_{i=1}^n S_i}{S_I}; \quad CAIDI = \frac{\sum_{i=1}^n (S_i \cdot T_i)}{\sum_{i=1}^n S_i} \quad (5.1)$$

unde:

S_i – puterea instalată a transformatoarelor de distribuție afectate în timpul unei avarii permanente i sau a unei întreruperi planificate i , [kVA];

T_i – durata în timp a avariei i sau a întreruperii planificate i , [minute/an];

S_l – puterea instalată a rețelei analizate, [kVA];

n – numărul de avarii sau de întreruperi pe o perioadă de un an.

Prin prelucrarea datelor înregistrate în mod continuu la dispeceratele regionale cu privire la avariile permanente în componentele rețelei de distribuție de MT (cauzate de defecte apărute în rețeaua de MT, precum și de defecte apărute în exteriorul rețelei de MT) și a întreruperilor planificate în RD de MT, se calculează, în fiecare an, valorile indicatorilor de siguranță în alimentarea consumatorilor din rețeaua respectivă.

Îmbunătățirea în ultimii ani a siguranței în alimentare a consumatorilor din societățile de electricitate din lume se datorează în special introducerii automatizării RD de MT, montării a mii de descărcătoare cu rezistență variabilă de tip "ZnO" și a execuției lucrărilor sub tensiune în rețelele de MT și JT. Obiectivul unora din aceste societăți este obținerea unei durate medii de nealimentare a consumatorilor cât mai reduse.

5.2.1.2. Metodologia stohastică

Deranjamentele care se produc în funcționarea rețelelor electrice fac parte din categoria întreruperilor și repunerilor în stare de funcționare, provocate de cauze interne, intempestive și involuntare, datorate defecțiunilor apărute în elementele proprii ale rețelei. Rețeaua electrică este readusă în stare de funcționare după repararea sau înlocuirea elementelor avariate. Întreruperile și readucerile în stare de funcționare ale elementelor rețelei au un caracter aleatoriu.

Evoluția în timp a sistemelor electrice de distribuție, cu un mod de comportare aleatoriu, se studiază cu ajutorul proceselor aleatorii sau stohastice, supuse legilor întâmplătoare sau hazardului. Elementele sistemului formează o familie de variabile aleatorii, ale căror valori descriu funcționarea în timp a sistemului.

În calcule se consideră că rețeaua electrică de distribuție este în stare de funcționare permanentă, ceea ce coincide cu situația reală, atât înainte de apariția unei întreruperi datorate defectării unui element component, cât și după repararea sau înlocuirea elementului avariât și readucerea schemei în starea de funcționare normală.

Indicatorii de fiabilitate ai RD de MT

Dintre toate metodele de calcul ale fiabilității sistemelor electroenergetice, prezentate în literatura de specialitate, se apreciază că modelul matematic cel mai

adecvat pentru descrierea comportării în timp a unei rețele electrice de distribuție îl constituie procesele stohastice de tip Markov. Indicatorii de fiabilitate, corespunzători metodei lanțurilor Markov, care se calculează cu ajutorul datelor statistice, obținute din înregistrările timpilor de funcționare și de defect în perioada de observație, sînt următorii:

- **Intensitatea de defectare,**

$$\lambda = \frac{1}{M[T_f]} [h^{-1}] \quad (5.2)$$

unde: $M[T_f]$ – timpul mediu de funcționare neîntreruptă;

- **Intensitatea de reparare,**

$$\mu = \frac{1}{M[T_d]} [h^{-1}] \quad (5.3)$$

unde: $M[T_d]$ – timpul mediu de defect neîntrerupt;

- **Probabilitatea de funcționare,**

$$P_s = \frac{\mu}{\lambda + \mu} \quad (5.4)$$

- **Probabilitatea de defectare,**

$$Q_s = \frac{\lambda}{\lambda + \mu} \quad (5.5)$$

- **Durata medie totală, probabilă a stării de succes,**

$$M[\alpha(T)] = \frac{\mu}{\lambda + \mu} \cdot T [h] \quad (5.6)$$

unde: T – timpul corespunzător pentru care se calculează indicatorii de fiabilitate;

- **Durata medie totală, probabilă a stării de refuz,**

$$M[\beta(T)] = \frac{\lambda}{\lambda + \mu} \cdot T \quad [h] \quad (5.7)$$

- Durata medie de întrerupere a sistemului,

$$DMIS = \frac{\sum M[\beta(T)]_i \cdot N_i}{\sum N_i} \quad [h] \quad (5.8)$$

unde: N_i – numărul consumatorilor în punctul de sarcină i .

Pentru calculul indicatorilor de fiabilitate mai sus menționați sînt necesare înregistrări continue ale timpilor de funcționare și de defect corespunzători elementelor componente ale rețelelor de distribuție. Ca exemplu, în Tabelele 5.1 și 5.2 sînt date valorile indicatorilor de fiabilitate (λ și μ) pentru liniile electrice, respectiv, pentru principalele echipamente electrice corespunzătoare rețelei electrice de MT [PE013 95].

Tabelul 5.1. Indicatorii de fiabilitate (λ și μ) pentru linii electrice

Tipul liniei	Indicatorii de fiabilitate	
	Intensitate de defectare λ [$10^{-4} \text{ h}^{-1}/\text{km linie}$]	Intensitatea de reparare μ [10^{-4} h^{-1}]
LEA 20 kV	0,04 ÷ 0,06	1000,0 ÷ 2000,0
LEC 20 kV	0,2 ÷ 0,4	100,0 ÷ 200,0

Tabelul 5.2. Indicatorii de fiabilitate pentru principalele echipamente electrice

Echipamentul	Indicatorii de fiabilitate [10^{-4} h^{-1}]	
	Intensitate de defectare λ	Intensitatea de reparare μ
Întrerupătoare (fără dispozitive de acționare)	0,01 ÷ 0,02	500,0 ÷ 1000,0
Separatoare	0,001 ÷ 0,004	400,0 ÷ 800,0
Transformatoare	0,01 ÷ 0,02	50,0 ÷ 100,0
Bare colectoare	0,01 ÷ 0,04	400,0 ÷ 600

În cazul Tabelul 5.1 se face precizarea că, în funcție de scopul urmărit în calcule, se va avea în vedere faptul că valorile parametrilor de fiabilitate indicate sînt valori medii și că pentru diverse perioade ale anului (vară, iarnă), parametrii respectivi pot avea valori diferite de cele medii [PE013 95].

5.2.1.3. Folosirea tehnicilor fuzzy

Incertitudinea indicatorilor de fiabilitate (λ și μ), va fi reprezentată în cele ce urmează cu ajutorul numerelor (mulțimilor) fuzzy. În mod similar vom proceda și cu lungimile tronsoanelor de cablu, care vor fi reprezentate tot prin numere fuzzy. Bazându-ne pe cunoștințele experților, pentru limitele inferioară/superioară ale indicatorilor de fiabilitate (λ și μ) și lungimii tronsoanelor (L_f), putem să stabilim categoriile lingvistice și să alegem funcțiile de apartenență pentru fiecare.

Astfel, în Fig. 5.2, 5.3 și 5.4 sînt prezentate funcțiile de apartenență corespunzătoare celor trei variabile lingvistice: **Small (S)**, **Medium (M)** și **Large (L)**, corespunzătoare liniilor în cablu, iar în Tabelele 5.3 și 5.4 sînt precizate valorile caracteristice ("breaking points") ale indicatorilor de fiabilitate (λ și μ) și lungimilor tronsoanelor de cablu pentru LEC 20 kV. În cele ce urmează semnificațiile mărimilor m – media, a – abaterea stînga, b – abaterea dreapta este cea definită în capitolul 2 pentru variabilele fuzzy triunghiulare [Cârțină 01/2], [Cârțină 03/3].

Tabelul 5.3. Valorile caracteristice (breaking points) ale lui λ și μ

	$\lambda [10^{-4}/h \cdot km]$			$\mu [10^{-4}/h]$		
	S	M	L	S	M	L
m	0,25	0,3	0,35	132,5	150	167,5
a	0,05	0,05	0,05	17,5	17,5	17,5
b	0,05	0,05	0,05	17,5	17,5	17,5

Tabelul 5.4. Valorile caracteristice pentru L_f , [m]

S	M	L
$m_{L_f S} = 662,5$	$m_{L_f M} = 1275$	$m_{L_f L} = 1887,5$
$a_{L_f S} = 612,5$	$a_{L_f M} = 612,5$	$a_{L_f L} = 612,5$
$b_{L_f S} = 612,5$	$b_{L_f M} = 612,5$	$b_{L_f L} = 612,5$






Fig. 5.2. Funcțiile de apartenență $u(\lambda)$

Fig. 5.3. Funcțiile de apartenență $u(\mu)$ Fig. 5.4. Funcțiile de apartenență pentru $\mu(L_f)$

Tehnica propusă a fost aplicată în câteva situații. În cazul de față s-a considerat o rețea de MT, Fig. 5.5, care este concepută în schemă buclată, cu funcționare normală radială.

Bucleara distribuitorilor se realizează pe barele de MT ale aceleși stații de distribuție 110/20 kV. Pentru ușurința calcului nu s-au luat în considerare circuitele de JT care pleacă din posturile de transformare. În funcționare normală, separatorul din PT3/PT4 este deschis. În anumite situații de defect în diferitele elemente din distribuția de medie tensiune, se va închide separatorul din PT3/PT4 și se va reda alimentarea consumatorilor total sau parțial, după natura defectului.




Fig. 5.5. Rețeaua de distribuție test

Avînd în vedere că numărul stărilor de defecte care pot să apară în acest caz este mare, pentru determinarea indicatorilor de fiabilitate se va folosi metoda bazată pe lanțuri Markov staționare, omogene și cu timp continuu, considerînd elementele independente.

Ținînd cont de relațiile de calcul a indicatorilor de fiabilitate prezentate anterior, precum și de valorile caracteristice ale indicatorilor de fiabilitate, în continuare, sînt prezentate rezultatele corespunzătoare duratei medii de întrerupere a alimentării pentru rețeaua de distribuție considerată. Pentru aceasta, s-au luat în considerare trei variante în care lungimile tronsoanelor de cablu diferă, Tabelul 5.5:

Tabelul 5.5. Lungimile tronsoanelor de rețea în cele trei variante considerate

Varianta	Tronsonul I		Tronsonul II		Tronsonul III	
	1	4	2	5	3	6
I	S	S	M	M	H	H
II	M	M	H	H	S	S
III	H	H	S	S	M	M

Deoarece există trei variabile de intrare (λ , μ și L_f) și una de ieșire – durata medie de întrerupere a sistemului (DMIS), regulile fuzzy pot fi reprezentate de o matrice fuzzy, Fuzzy Associate Memory (FAM). Folosind criteriul $(n-1)$, în Tabelul 5.6, sînt prezentate valorile FAM posibile, rezulate pe baza descrierii lingvistice a variabilelor de intrare (λ , μ și L_f). Pentru durata medie de întrerupere a sistemului (DMIS) s-a avut în vedere o reprezentare prin cinci categorii lingvistice: **Strongly Prefer (SP)** (0,50÷0,65), **Moderately Prefer (MP)** (0,65÷0,95), **Neutral (NT)** (0,95÷1,25), **Moderately Against (MA)** (1,25÷1,55) și **Strongly Against (SA)** (1,55÷1,70), Fig. 5.6.




Fig. 5.6. Funcțiile de apartenență pentru DMIS

Tabelul 5.6. FAM pentru durata medie de întrerupere a rețelei (DMIS)

		λ								
		S			M			H		
L_r	III	m=0,81 a=0,31 b=0,57 cr=0,90	m=0,75 a=0,25 b=0,47 cr=0,82	m=0,58 a=0,20 b=0,39 cr=0,64	m=1,17 a=0,43 b=0,75 cr=1,27	m=0,97 a=0,34 b=0,61 cr=1,06	m=0,83 a=0,28 b=0,51 cr=0,91	m=1,55 a=0,58 b=0,94 cr=1,67	m=1,29 a=0,46 b=0,77 cr=1,40	m=1,10 a=0,37 b=0,65 cr=1,20
		MP	MP	SP	MA	NT	MP	SA	MA	NT
	II	m=0,80 a=0,30 b=0,57 cr=0,9	m=0,74 a=0,24 b=0,46 cr=0,82	m=0,57 a=0,19 b=0,38 cr=0,64	m=1,15 a=0,43 b=0,74 cr=1,25	m=0,96 a=0,34 b=0,60 cr=1,05	m=0,82 a=0,27 b=0,50 cr=0,90	m=1,53 a=0,57 b=0,93 cr=1,65	m=1,28 a=0,45 b=0,76 cr=1,38	m=1,09 a=0,36 b=0,64 cr=1,18
		MP	MP	SP	MA	NT	MP	SA	MA	NT
I		m=0,74 a=0,27 b=0,52 cr=0,82	m=0,62 a=0,21 b=0,43 cr=0,69	m=0,53 a=0,17 b=0,35 cr=0,59	m=1,05 a=0,38 b=0,69 cr=1,16	m=0,89 a=0,30 b=0,56 cr=0,97	m=0,76 a=0,24 b=0,47 cr=0,84	m=1,40 a=0,51 b=0,87 cr=1,52	m=1,18 a=0,40 b=0,71 cr=1,28	m=1,01 a=0,32 b=0,60 cr=1,10
		MP	MP	SP	NT	NT	MP	MA	MA	NT
		S	M	H	S	M	H	S	M	H
		μ			μ			μ		

Analizând rezultatele din Tabelul 5.6 se observă că mărirea lungimii tronsoanelor se traduce printr-o creștere a duratei de nealimentare. Pentru o anumită categorie

lingvistică a indicatorilor de fiabilitate λ și μ , de exemplu S, DMIS crește de la varianta I la varianta III. În același timp, pentru un anumit caz, de exemplu varianta I, și o anumită categorie lingvistică pentru λ , DMIS descrește de la categoria lingvistică S, la categoria lingvistică H a lui μ .

În acest paragraf s-a prezentat un posibil câmp de aplicații pentru tehnicile fuzzy în domeniul analizei fiabilității sistemelor de distribuție. Astfel, indicatorii de fiabilitate (λ și μ) și lungimea tronsoanelor de cablu (L_f) sînt modelate ca variabile lingvistice și numere fuzzy. Metoda descrisă mai sus folosește pentru datele de intrare, λ , μ și L_f , descrise ca variabile lingvistice, și funcții de apartenență triunghiulare ("breaking points"). Astfel, se poate determina durata medie de întrerupere a sistemului (în cazul nostru a rețelei) (DMIS), într-o manieră mai nuanțată, în raport cu cea deterministă.

5.2.1.4. Considerarea factorului timp în determinarea indicatorilor de fiabilitate

În condițiile actuale de exploatare a sistemelor de distribuție, în care diferitele instalații sau echipamente cumulează anumite durate de funcționare și, în consecință, prezintă unele fenomene de degradare (îmbătrânire, uzură etc), devin oportune acțiuni de reabilitare sau chiar re tehnologizare. Asemenea acțiuni determină perioadele de timp în care schemele structurale ale instalațiilor suferă modificări de natură a influența în mod negativ siguranța lor în funcționare.

Considerațiile se fac în ipoteza că, în prezent și pentru o bună perioadă de timp, nu vor exista la sucursalele de distribuție, informații statistice pentru stabilirea suficient de exactă a modului de variație a indicatorilor de fiabilitate, corespunzători diverselor echipamente. Pentru moment aceste informații se rezumă, în cel mai bun caz, la înregistrarea numărului mediu de defecte în unitatea de timp de funcționare.

În cadrul acestui paragraf se urmărește ca, pe baza unor informații cu caracter limitat, să se evalueze influența degradării în timp a echipamentelor electrice, datorită diferitelor cauze specifice. O astfel de posibilitate se consideră utilă și necesară în activitatea de exploatare, dar mai ales în planificarea dezvoltării sistemelor de distribuție.

Considerații privind estimarea intensității de defectare

Obiectivul principal al analizelor de estimare a fiabilității este de a cuantifica, a estima și a compara indicatorii de fiabilitate pentru diferite strategii de îmbunătățire a fiabilității sistemelor de distribuție [Brint 98], [Christopher 99]. Studiile de

lingvistică a indicatorilor de fiabilitate λ și μ , de exemplu S, DMIS crește de la varianta I la varianta III. În același timp, pentru un anumit caz, de exemplu varianta I, și o anumită categorie lingvistică pentru λ , DMIS descrește de la categoria lingvistică S, la categoria lingvistică H a lui μ .

În acest paragraf s-a prezentat un posibil câmp de aplicații pentru tehnicile fuzzy în domeniul analizei fiabilității sistemelor de distribuție. Astfel, indicatorii de fiabilitate (λ și μ) și lungimea tronsoanelor de cablu (L_f) sînt modelate ca variabile lingvistice și numere fuzzy. Metoda descrisă mai sus folosește pentru datele de intrare, λ , μ și L_f , descrise ca variabile lingvistice, și funcții de apartenență triunghiulare ("breaking points"). Astfel, se poate determina durata medie de întrerupere a sistemului (în cazul nostru a rețelei) (DMIS), într-o manieră mai nuanțată, în raport cu cea deterministă.

5.2.1.4. Considerarea factorului timp în determinarea indicatorilor de fiabilitate

În condițiile actuale de exploatare a sistemelor de distribuție, în care diferitele instalații sau echipamente cumulează anumite durate de funcționare și, în consecință, prezintă unele fenomene de degradare (îmbătrânire, uzură etc), devin oportune acțiuni de reabilitare sau chiar retehnologizare. Asemenea acțiuni determină perioadele de timp în care schemele structurale ale instalațiilor suferă modificări de natură a influența în mod negativ siguranța lor în funcționare.

Considerațiile se fac în ipoteza că, în prezent și pentru o bună perioadă de timp, nu vor exista la sucursalele de distribuție, informații statistice pentru stabilirea suficient de exactă a modului de variație a indicatorilor de fiabilitate, corespunzători diverselor echipamente. Pentru moment aceste informații se rezumă, în cel mai bun caz, la înregistrarea numărului mediu de defecte în unitatea de timp de funcționare.

În cadrul acestui paragraf se urmărește ca, pe baza unor informații cu caracter limitat, să se evalueze influența degradării în timp a echipamentelor electrice, datorită diferitelor cauze specifice. O astfel de posibilitate se consideră utilă și necesară în activitatea de exploatare, dar mai ales în planificarea dezvoltării sistemelor de distribuție.

Considerații privind estimarea intensității de defectare

Obiectivul principal al analizelor de estimare a fiabilității este de a cuantifica, a estima și a compara indicatorii de fiabilitate pentru diferite strategii de îmbunătățire a fiabilității sistemelor de distribuție [Brint 98], [Christopher 99]. Studiile de

estimare a fiabilității pot fi efectuate pentru diverse perioade de timp. În timpul acestor perioade, una din componentele informației care se obține este modul de variație în timp a intensității de defectare a diverselor echipamente.

Datorită dezvoltării tehnicilor de Inteligență artificială aceste studii de estimare pot fi făcute astăzi cu o mai mare ușurință. Disponibilitatea sistemelor bazate pe Inteligența artificială asigură utilizatorului mijloacele necesare obținerii variației în timp a intensității de defectare și timpilor de defectare a diverselor echipamente electrice, pe baza datelor actuale cu privire la numărul mediu de defecte în perioada de timp, precum și o capacitate de calcul a indicatorilor de fiabilitate cu o precizie suficient de bună.

Aceste sisteme inteligente pot fi utilizate pentru [Burke 00]:

- folosirea informațiilor actuale la asigurarea preciziei studiilor de estimare a fiabilității;
- stabilirea suficient de precisă a intensităților de defectare și timpilor de defectare;
- identificarea terenurilor care contribuie la înrăutățirea indicatorilor de fiabilitate ai echipamentelor electrice;
- stabilirea fiabilității sistemelor de distribuție fără folosirea unor sisteme de monitorizare scumpe etc.

Informațiile cu privire la intensitatea de defectare a echipamentelor sînt extrem de importante în orice studiu de estimare a variației în timp a acesteia. Astăzi, există multe întrebări care și le pun companiile de electricitate în ceea ce privește folosirea acestor informații. Dintre aceste întrebări, vom enumera pe cele mai importante [Burke 00]:

- Este intensitatea de defectare prioritară pentru unul sau mai mulți fabricanți ai aceluiasi echipament ?
- Cît de mult influențează condițiile geografice intensitățile de defectare ?
- Ce includ intensitățile de defectare? Includ, de exemplu, și influența animalelor (păsări), în cazul LEA ?
- Este vârsta unui echipament un factor important care trebuie luat în seamă pentru intensitățile de defectare?

Cînd trecem în revistă toate aceste întrebări, este important să observăm că răspunsurile influențează foarte mult intensitățile de defectare ale echipamentelor.

Estimarea variației în timp a intensității de defectare cu ajutorul funcției Weibull

Variația comportării în timp a intensității de defectare $\lambda(t)$ a diferitelor echipamente electrice poate fi modelată cu ajutorul funcției de repartiție Weibull. Această funcție are următoarea expresie [Stein 99]:

$$\lambda(t) = \frac{\beta \cdot t^{\beta-1}}{\alpha^\beta} \quad (5.9)$$




Fig. 5.7. Graficul funcției $\lambda(t)$

Graficul funcției este dat în Fig.5.7. Din analiza graficului se pot desprinde următoarele concluzii:

- Pentru $\beta = 1$, funcția devine o funcție exponențială cu $\lambda = \text{const.}$
- Curba corespunzătoare pentru $\beta < 1$ nu poate fi luată în considerare, deoarece aceasta ar reprezenta o scădere a nivelului de degradare în timp.
- Curbele corespunzătoare pentru $1 < \beta < 2$, corespund cazului în care gradul de degradare în timp tinde către saturație, lucru imposibil de realizat.
- Valorile mai mari de 2,5 determină trecerea funcției Weibull într-o funcție de repartiție normală.

- Singurele curbe care pot fi luate în considerare pentru modelarea degradării în timp, sînt cele care se încadrează între valorile 2 și 2,5, corespunzătoare parametrului β .
- Pentru durate mai mici de valoarea t_{critic} , considerarea funcției exponențiale permite obținerea unor valori acoperitoare, iar după această durată, valorile funcției Weibull vor fi mai dezavantajoase pentru considerarea fiabilității.

În cadrul rel. (5.9), pentru simplificarea calculelor se poate considera [Stein 00]:

$$\alpha \cong \frac{1}{\lambda(t=0)} = M[T_f], \quad 2 \leq \beta \leq 2,5 \quad (5.10)$$

În vederea obținerii valorii corespunzătoare lui t_{critic} vom utiliza expresia:

$$t_{critic} = \alpha \cdot \left(\frac{1}{\beta} \right)^{\frac{1}{\beta-1}} \quad (5.11)$$

Modelarea variației în timp a intensității de defectare prin tehnici fuzzy

Ideea de bază a teoriei mulțimii fuzzy este să modeleze și să fie capabilă să lucreze cu incertitudini. Modelele matematice și algoritmi din teoria sistemelor electroenergetice tind, pe cît posibil, să fie cît mai aproape de realitate. Măsurătorile solicitate de om și restricțiile din timpul proceselor modelate sînt întotdeauna o sursă de imprecizie.

Incetitudinile din teoria fuzzy sînt o măsură a nespecificității care este caracterizată prin posibilitatea de distribuție. Aceasta este oarecum similară folosirii distribuției probabilității, care caracterizează incetitudinea în teoria probabilității.

Incetitudinea parametrului α , (rel. 5.10), și dependența de timp, din cadrul funcției Weibull, va fi reprezentată în cele ce urmează cu ajutorul numerelor (mulțimilor) fuzzy. Bazîndu-ne pe cunoștințelor experților, pentru limitele inferioară/superioară ale parametrului α , putem să fixăm variabilele lingvistice și să alegem funcțiile de apartenență corespunzătoare. La fel vom proceda și în cazul variabilei timp t , dar, pentru aceasta vom fixa ca limită inferioară o valoare mai mare decît t_{critic} , (rel. 5.11), iar ca valoare superioară o valoare corespunzătoare unei durate de timp care interesează în cadrul studiului [Cârțină 01/5], [Cârțină 03/4].

Astfel, în Fig. 5.8 și 5.9 sînt prezentate funcțiile de apartenență corespunzătoare celor trei categorii lingvistice: **Small (S)**, **Medium (M)** și **Large (L)**, pentru parametrii α și t , iar în Tabelele 5.7 și 5.8, sînt precizate valorile

caracteristice ("breaking points") ale acestora. Trebuie să facem precizarea că valorile parametrului α au fost obținute cu ajutorul rel. (5.10), ținând seama de informațiile cu privire la valorile intensității de defectare care se găsesc în [PE013 95], pentru o linie electrică în cablu.

Se poate considera și cazul particular în care $\alpha = 1/(\lambda(t=0)) = \text{const}$. În ceea ce privește parametrul β , din cadrul expresiei (5.9), acesta s-a considerat constant, $\beta = 2$. Această valoare corespunde situației care ne interesează în cadrul studiului, și anume de modelare a variației în timp a intensității de defectare, $\lambda(t)$.

Tabelul 5.7. Valorile caracteristice pentru α


S	M	L
$m_{\alpha S} = 3,375$	$m_{\alpha M} = 3,750$	$m_{\alpha L} = 4,125$
$a_{\alpha S} = 0,375$	$a_{\alpha M} = 0,375$	$a_{\alpha L} = 0,375$
$b_{\alpha S} = 0,300$	$b_{\alpha M} = 0,300$	$b_{\alpha L} = 0,300$



Tabelul 5.8. Valorile caracteristice pentru t [ani]

S	M	L
$m_{tS} = 2,375$	$m_{tM} = 3,250$	$m_{tL} = 4,125$
$a_{tS} = 0,875$	$a_{tM} = 0,875$	$a_{tL} = 0,875$
$b_{tS} = 0,875$	$b_{tM} = 0,875$	$b_{tL} = 0,875$

Semnificația parametrilor m , a , b , din Tabelele 5.7 și 5.8, este cea atribuită în capitolul 2 pentru variabilele fuzzy triunghiulare.

Deoarece există două variabile de intrare (α și t) și una de ieșire – variația în timp a intensității de defectare $\lambda(t, \alpha)$, regulile fuzzy pot fi reprezentate de o matrice fuzzy (Fuzzy Associate Memory (FAM)).

Fig. 5.8. Funcțiile de apartenență $\mu(\alpha)$

Fig. 5.9. Funcțiile de apartenență $\mu(t)$ Fig. 5.10. Funcțiile de apartenență $\mu(\lambda(t, \alpha))$ Tabelul 5.9. Matricea fuzzy corespunzătoare lui $\lambda(t, \alpha)$

α	L	$m = 0,27916;$ $a = 0,06582;$ $b = 0,05281;$ $Crisp = 0,27482;$ S	$m = 0,3820;$ $a = 0,0442;$ $b = 0,0393;$ $Crisp = 0,38037;$ S	$m = 0,48485;$ $a = 0,02263;$ $b = 0,02586;$ $Crisp = 0,48593;$ M
	M	$m = 0,33778;$ $a = 0,0744;$ $b = 0,0585;$ $Crisp = 0,33248;$ S	$m = 0,46222;$ $a = 0,04521;$ $b = 0,04075;$ $Crisp = 0,46073;$ M	$m = 0,58667;$ $a = 0,01602;$ $b = 0,0230;$ $Crisp = 0,58899;$ L
	S	$m = 0,41701;$ $a = 0,08368;$ $b = 0,06427;$ $Crisp = 0,41054;$ S	$m = 0,57064;$ $a = 0,04287;$ $b = 0,04021;$ $Crisp = 0,56976;$ L	$m = 0,72428;$ $a = 0,00206;$ $b = 0,01615;$ $Crisp = 0,72898;$ L
		S	M	L
		t		

Folosind metodologia prezentată anterior, în Tabelul 5.9, sînt prezentate valorile FAM posibile, rezultate pe baza descrierii lingvistice a variabilelor de intrare (α și t). Pentru $\lambda(t, \alpha)$ s-a avut în vedere o reprezentare prin trei categorii lingvistice, Fig. 5.10: **Small (S)** ($0,25 \div 0,4125$), **Medium (M)** ($0,4125 \div 0,5625$) și **Large (L)** ($0,5625 \div 0,75$).

Din analiza Tabelului 5.9 se observă că mărirea duratei de timp se traduce printr-o creștere a intensității de defectare. Se mai poate vedea că intensitatea de defectare crește de la stînga la dreapta și de sus în jos în cadrul tabelului. Valorile cele mai mici corespund situației în care $\alpha - L$, $t - S$, iar valorile cele mai mari corespund situației în care $\alpha - S$ și $t - L$. Dispersiile obținute pentru fiecare caz în parte sînt cu mult mai mici decît valoarea medie, ceea ce face ca valoarea crisp obținută să fie foarte aproape de valoarea medie a lui $\lambda(t, \alpha)$.

Exemplu de aplicație

Plecînd de la relațiile de calcul ale indicatorilor de fiabilitate prezentate anterior, precum și de la valorile caracteristice ("breaking points") ale indicatorilor de fiabilitate λ și μ , în continuare, sînt prezentate rezultatele corespunzătoare duratei medii de întrerupere a alimentării pentru o rețeaua de distribuție test (20 kV) din Fig. 5.11. Lungimile tronsoanelor de linie (în km) sînt cele indicate în figură.

Datorită faptului că intensitățile de defectare ale echipamentelor din rețelele electrice variază în timp, durata medie de întrerupere în alimentarea cu energie electrică se modifică. Pentru a observa cum se modifică durata medie de întrerupere (DMIS) s-a presupus că o anumită porțiune dintr-un tronson de linie (hașurat) din rețeaua de distribuție test, Fig 5.11, are o intensitate de defectare care variază în timp (crește) datorită unor fenomene de degradare (îmbătrînire, uzură etc).

Pentru aceasta, s-au considerat mai multe situații în care porțiunea de tronson supusă degradării în timp (ce are o intensitate de defectare $\lambda(t > t_{cr})$) reprezintă 25, 50, respectiv 75% din lungimea tronsonului de cablu. Rezultatele obținute pentru situațiile considerate au fost comparate cu cazul $\lambda(t < t_{cr})$ în ceea ce privește durata medie de întrerupere a sistemului (DMIS).

Pentru DMIS s-a avut în vedere o reprezentare prin cinci categorii lingvistice, Fig. 5.12:

Strongly Prefer (SP):	$0,550 \div 0,675$;
Moderately Prefer (MP):	$0,675 \div 0,925$;
Neutral (NT):	$0,925 \div 1,175$;
Moderately Against (MA):	$1,175 \div 1,425$;
Strongly Against (SA):	$1,425 \div 1,550$.




Fig. 5.11. Exemplu de rețea de distribuție




Fig. 5.12. Funcțiile de apartenență pentru DMIS

Tabelul 5.10. FAM pentru durata medie de întrerupere a rețelei
(cazul λ ($t < t_{cr}$)), [h/an]

μ	L	m = 0,4643; a = 0,0409; b = 0,0357; Crisp = 0,4626; SP	m = 0,6829; a = 0,0433; b = 0,0352; Crisp = 0,6802; MP	m = 1,0331; a = 0,0351; b = 0,0245; Crisp = 1,0296; NT
	M	m = 0,5345; a = 0,0477; b = 0,0397; Crisp = 0,5318; SP	m = 0,7879; a = 0,0480; b = 0,0370; Crisp = 0,7842; MP	m = 1,2055; a = 0,0305; b = 0,0183; Crisp = 1,2015; MA
	S	m = 0,6285; a = 0,0554; b = 0,0435; Crisp = 0,6245; SP	m = 0,9291; a = 0,0515; b = 0,0366; Crisp = 0,9241; MP	m = 1,4400; a = 0,0165; b = 0,0440; Crisp = 1,4359; SA
		S	M	L
λ				

Tabelul 5.11. FAM pentru durata medie de întrerupere a rețelei (cazul λ ($t > t_{cr}$))
pentru 75% din lungimea tronsonului supus degradării în timp), [h/an]

μ	L	m = 0,5657; a = 0,0568; b = 0,0481; Crisp = 0,5628; SP	m = 0,8229; a = 0,0566; b = 0,0451; Crisp = 0,8190; MP	m = 1,1035; a = 0,0508; b = 0,0380; Crisp = 1,0992; NT
	M	m = 0,6609; a = 0,0646; b = 0,0521; Crisp = 0,6567; SP	m = 0,9624; a = 0,0603; b = 0,0454; Crisp = 0,9574; NT	m = 1,2932; a = 0,0481; b = 0,0329; Crisp = 1,2882; MA
	S	m = 0,7904; a = 0,0722; b = 0,0546; Crisp = 0,7846; MP	m = 1,1527; a = 0,0600; b = 0,0411; Crisp = 1,1464; NT	m = 1,5524; a = 0,0359; b = 0,0195; Crisp = 1,5469; SA
		S	M	L
λ				

Analiza rezultatelor obținute în Tabelele 5.10 și 5.11 indică faptul că valorile parametrului m corespunzător duratei medii de întrerupere a sistemului cresc în cazul în care intensitatea de defectare a tronsonului supus degradării se modifică în timp. Cele mai mari valori sînt obținute în cazul $\lambda = L$.

5.2.2. Impactul asupra mediului ambiant

Impactul rețelelor electrice asupra mediului înconjurător este un aspect deosebit de important, care trebuie să fie luat în considerare la proiectarea/modernizarea instalațiilor energetice. Aspectele privind mediul vor crește ca importanță în viitor. Mediul este luat în considerare într-un sens larg ce include priorități politice, opinia publică, cerințele altor factori din societate [Mazeac 96]. Din această cauză, multe companii de electricitate au intenția să acorde mediului înconjurător un loc important în studiile de dezvoltare ale rețelelor electrice [Trocme 96].

Deși opiniile și cererile nu pot fi în mod exact aceleași în toate țările, în general, se consideră că linia electrică ce traversează peisajele naturale are un impact negativ asupra mediului. La o examinare riguroasă, se poate constata faptul că efectul impactului negativ asupra mediului variază foarte mult. Astfel, în unele situații, linia electrică creează un șoc real, iar în altele, ea este văzută ca o parte normală și familiară a peisajului.

Pentru modernizarea, planificarea sau exploatarea unor sisteme de distribuție, cea mai mare parte a literaturii de specialitate se concentrează pe dezvoltarea modelelor matematice. Modelele matematice sînt uneori nerealiste sau necorespunzătoare pentru modelarea problemelor neingineresti, cum ar fi spre exemplu, impactul mediului sau restricțiile geologice/geografice etc. Din păcate este important pentru ingineri să abordeze și aceste probleme.

Integrarea în mediu solicită o investigare corectă și atentă a terenurilor/zonelor respective. Pentru acest domeniu pare să se contureze o politică pentru planificarea rețelelor de distribuție, pentru perioada următoare. Aceasta necesită o foarte bună alegere a traseelor pentru liniile electrice și soluții adecvate pentru stațiile electrice. Fixarea traseelor optime impune luarea în considerare a unei serii de factori (căi ferate, șosele, impactul asupra mediului și altele), care au o influență directă în costul investiției.

Aceste restricții fizice/geografice nu sînt ușor de cuantificat și sînt anevoioase/inproprii pentru a fi modelate matematic. În acest caz, metodele tradiționale de planificare/optimizare sînt cel mai adesea ineficace. În schimb, metodele euristice dau rezultate bune. Principiul folosit de aceste metode euristice este trecerea în revistă a tuturor combinațiilor posibile între diferite variante, calcularea funcției obiectiv și selecționarea soluției optime. Metodele euristice păcătuiesc, în cazul studiilor reale, prin numărul mare de combinații posibile. Pentru

a reduce acest număr, decidentul/programatorul elimină o parte din combinații, încă din faza inițială, și anume combinațiile pe care le consideră puțin plauzibile. Experiența arată că aceste metode euristice dau rezultate bune, mai ales dacă sunt urmate de un program de proiectare dinamică interactiv.

Considerând un model dinamic al planificării rețelei, cu ajutorul intervențiilor interactive, bazate pe metode euristice, chiar și acele restricții, care sunt foarte greu de exprimat numeric, pot fi luate în considerare.

Astfel, nu este necesar să se furnizeze programului de calcul, încă de la începutul planificării, toate datele. Aceasta poate conduce la dificultăți mari de programare. Este mai eficient să se adauge/corecteze o parte din date, într-o manieră interactivă.

Din această cauză, pentru integrarea/absorbția liniilor electrice aeriene, din punct de vedere al mediului, este necesar, de asemenea, să se stabilească, de îndată ce este posibil, o bază de criterii și reguli coerente și aplicabilă pentru o arie largă de situații. De exemplu, în Elveția asemenea reguli au fost stabilite de un grup de experți, și au devenit un document esențial în soluționarea respectivei probleme. Un asemenea document definește principalele reguli pentru stabilirea traseului liniilor electrice [Trocme 96]:

- minimizarea impactului ecologic și estetic asupra mediului evitând terenurile protejate;
- gruparea, dacă este posibil, cu alte infrastructuri (căi ferate, șosele, rețele de telecomunicații);
- adaptarea la mediu.

În practică, se poate lua în considerare peisajul, în timpul procesului de planificare a traseului unei linii, parcurgând următoarele etape [Laurent 96]:

- examinarea, analiza terenului și divizarea acestuia în suprafețe mici, depinzând de impactul lor asupra mediului;
- construirea unui program interactiv care să faciliteze fixarea unei valori pentru fiecare sector al liniei și să fie capabil să examineze și să compare traseele alternative, posibile;
- după o primă alegere a traseului, putem considera detaliile (tipul, profilul stâlpilor și altele).

Un asemenea algoritm poate fi și practic mai ales datorită folosirii unor tehnici adecvate, așa cum se va vedea în continuare.

În dezvoltarea structurii rețelelor de distribuție de MT, în multe țări accentul se pune pe îngroparea rețelelor rurale. Trei grade de restricții pot fi luate în considerare în acest caz [Romanello 95]:

- nici o restricție: nu există nici o obligație de a îngropa liniile electrice aeriene;
- restricții medii: rețelele de MT trebuie să aibă 30-40% cablu îngropat;
- restricții severe: rețelele de MT trebuie să aibă 60% cablu îngropat.

Problema îngropării liniilor de MT și JT trebuie tratată cu foarte mare atenție. Această îngropare nu trebuie să se facă oricum, pentru că se poate transforma într-un rău și mai mare [Cabanel 96].

Complexitatea sistemelor de distribuție a reprezentat o motivație puternică pentru introducerea noilor tehnologii de informații – Geographic Information System (GIS) care să ajute la analiza eficientă a soluțiilor (prognoza sarcinii, optimizarea structurii rețelelor de distribuție etc) într-un interval de timp cât mai scurt și cu o precizie corespunzătoare. S-a dovedit că într-adevăr folosirea GIS permite reprezentarea sistemelor de distribuție în detaliu pentru a ușura activitățile de exploatare și planificare, iar pe de altă parte, permite o însemnată economisire a unui volum de muncă, realizat anterior manual în cea mai mare parte.

5.3. Utilizarea tehnicilor GIS (Geographic Information Systems)

5.3.1. Sistemul GIS

Sistemul GIS (Geographic Information System) a fost introdus pentru prima dată în anul 1960. La început sistemul GIS s-a limitat la un număr restrâns de aplicații și cercetări. Astăzi sistemul GIS este unul dintre sistemele ce înregistrează o utilizare și creștere tehnologică deosebită, cu aplicații în siguranța publică, managementul resurselor naturale, analize ale mediului înconjurător, servicii și înaintea rapid și în alte domenii.

Principalele aplicații integrate ale sistemelor GIS se referă la:

- planificarea dezvoltării managementului orașelor;
- studiul căilor de comunicație;
- studiul mediului și al impactului asupra mediului;
- managementul datelor spațiale a rețelelor publice de apă, electricitate, canalizare etc;
- localizarea și monitorizarea vehiculelor publice;
- producerea și emiterea certificatelor și autorizațiilor către public.

Motivația pentru utilizarea intensă a sistemului GIS o constituie legătură dintre nevoia de a dispune de un volum de informații din ce în ce mai ridicat și creșterea tehnologiei de calcul care să asigure procesarea și accesul rapid la informații într-un timp foarte scurt.

Din punct de vedere conceptual un sistem GIS poate fi privit ca avînd o stivă de hărți, în care fiecare strat este corelat spațial cu celelalte, Fig. 5.13 [Queen www].

Fiecare strat conține un singur tip de informații sau teme geografice. Fiecare temă poate include, de exemplu, informații topologice, despre natura solului, despre o anumită regiune, de infrastructură (căi de comunicații, conducte, linii electrice etc).




Fig. 5.13. Modelul conceptual al unui sistem GIS

Cele mai simple funcții ale unui sistem GIS asigură o versiune automată a unei hărți tradiționale. Realizarea unor hărți prin suprapunere electronică este probabil cea mai obișnuită funcție a sistemelor GIS. Această funcție, în trecut, era realizată manual, folosind hărți întocmite după niște tabele de date sau tehnici fotografice. Utilizatorul poate accesa, suprapune, manipula și analiza rapid orice număr sau combinații de hărți/straturi. Acesta poate evalua rezultatele analizei prin afișarea pe ecranul monitorului, copie hard a hărții construită de sistemul GIS sau poate salva rezultatele într-un format tabel. Oricât de simplu sau de complex este obiectivul avut în vedere, un sistem GIS este conceput să acceseze o bază de date sub formă de hărți care pot fi suprapuse, combinate și analizate după dorință [Queen www].

Un sistem GIS asigură o bază de date hibridă, ce conține atât informații spațiale cât și informații de atribuire. Informațiile spațiale descriu localizarea obiectelor într-un sistem de coordonate cunoscut, în timp ce informațiile de atribuire descriu natura sau caracteristicile obiectelor, Fig. 5.14.





Fig. 5.14. Model de stocare a informațiilor spațiale și de tip atribut



Tabel cu informații geografice

Obiecte	Coordonate X,Y	Obiect
A	5,1	Casă
B	0,7; 1,7; 1,6; 2,5; 1,4; 2,3; 3,3; 2,1;	Rețea electrică
C	4,3; 5,3; 6,4; 6,5; 6,6; 7,7; 6,8; 4,7; 3,5; 4,3	Lac

Fig. 5.15. Modul de întocmire a hărților în sistemul GIS

Pentru ca o hartă să fie corectă din punct de vedere geografic și a relațiilor dintre informații (de exemplu, între căi de comunicații și orașe), cartograful trebuie să aibă în vedere un set de reguli precise. Pentru atingerea obiectivului avut în vedere, se va simplifica acest set de reguli la trei, cele mai importante care trebuie respectate fiind: sistemele de coordonate, proiecțiile și scara de reprezentare, Fig. 5.15 [Queen www].

Numai în momentul în care aceste reguli sînt respectate se poate construi corect o hartă. O bază de date exactă a sistemului GIS depinde de disponibilitatea și utilizarea unor hărți originale corecte.

Informațiile pot fi manipulate (culese, stocate, analizate) într-un sistem GIS folosind o serie de programe funcționale care lucrează cu documente de tip imagine.

În sistemul GIS există cîteva metode de procesare a informațiilor, cum ar fi [Queen www]:

- scanarea hărților;
- corecția hărților;
- importul de documente ce conțin informații spațiale;
- structuri de date (ce pot fi înregistrate, analizate și transformate etc);
- comunicarea cu alte programe și aplicații.

Sistemul GIS conține mai mult decît informații și software. Ca sistem, a fost creat pentru a da răspunsuri la întrebările legate de informațiile geografice și spațiale, răspunsuri care să asigure suportul luării deciziilor în diverse activități.

Pentru a avea un sistem GIS nu este de ajuns să se dispună doar de informații, hardware, software sau de utilizatori. Toate aceste componente trebuie să fie prezente pentru a putea avea un sistem GIS funcțional. Astfel, un sistem GIS este alcătuit din 4 componente: **date, parte hardware, parte software și utilizatori**, Fig. 5.16.

Sistemul GIS va realiza modificări profunde în ceea ce privește achiziția, stocarea, analiza informațiilor geografice. Multe dintre aceste modificări sînt estimate iar impactul lor poate fi estimat înainte ca acestea să se producă. Fiecare sistem GIS este unic, avînd propriile informații, hardware și software, ce trebuie să corespundă cerințelor utilizatorului.




Fig. 5.16. Componentele unui sistem GIS

5.3.2. Rolul GIS în planificarea și exploatarea optimală

Companiile de electricitate au nevoie de un inventar general și exact al bunurilor fizice, a dispozițiilor serviciului de exploatare (extinderea rețelei de distribuție, efectuarea operațiilor de mentenanță etc) cât și a obligațiilor de informare a terților despre facilitățile lor. Complexitatea sistemelor de distribuție a reprezentat o motivație puternică pentru introducerea noilor tehnologii de informații – GIS care să ajute la analiza eficientă a soluțiilor (prognoza sarcinii, optimizarea structurii rețelelor de distribuție etc) într-un interval de timp cât mai scurt și cu o precizie corespunzătoare.

Planificarea optimală a sistemelor de distribuție a energiei electrice este privită ca o problemă deosebit de complexă datorită numărului mare de variabile și configurații posibile de rețea referitoare la caracteristicile suprafeței geografice și consumatorilor deserviți [Skrlek www].

În problemele de planificare, obiectivul major poate lua forma construirii unei noi stații, introducerii sau înlocuirii unor transformatoare într-o stație, introducerii unor noi fideri de plecare dintr-o stație, instalarea sau înlocuirea unor cabluri sau conductoare. Problemele complexe de optimizare apar, în particular, pentru rețelele rurale care traversează zone interzise. În orașe, numărul mare de restricții impun reducerea considerabilă a numărului de soluții posibile.

Unul din primii pași din cadrul planificării dezvoltării îl constituie prognoza sarcinii. Un alt pas al planificării este construirea propriu zisă a rețelelor de medie și

joasă tensiune. Aceasta reclamă o foarte bună alegere a traseului pentru liniile electrice. Stabilirea traseelor optime impune luarea în considerare a unei serii de factori care au influență directă asupra costului de investiții (căi ferate, șosele, impactul asupra mediului etc). Un aspect deosebit de important care trebuie luat în considerare este impactul liniilor electrice asupra mediului.

Obiectivele procesului de proiectare a unui sistem de distribuție poate fi împărțit în trei părți [Skrlek www]:

- **Prognoza sarcinii:**
 - creșterea sarcinii pe suprafața geografică deservită de stația electrică;
 - determinarea mărimii sarcinii și poziționarea ei geografică;
 - caracteristicile de sarcină ale consumatorului.
- **Proiectarea rețelelor de joasă tensiune:**
 - amplasarea optimă a posturilor de transformare și dimensionarea transformatoarelor MT/JT;
 - determinarea traseelor optime și dimensionarea optimă pentru fiderii de joasă tensiune;
- **Proiectarea rețelelor de medie tensiune:**
 - amplasarea optimă a posturilor de transformare;
 - determinarea traseelor optime și dimensionarea optimă pentru fiderii de medie tensiune.

5.3.3. Integrarea și procesarea documentelor de tip GIS în MatLab

În cadrul acestui paragraf se prezintă o metodologie destinată îmbunătățirii deciziilor privind modernizarea liniilor electrice de medie tensiune (MT). Se are în vedere o abordare cât mai realistă a problemei respective, care să considere mai multe criterii de optimizare ce intervin în cazurile concrete de dezvoltare/modernizare a instalațiilor energetice.

O parte din aceste criterii sînt greu de cuantificat în modelele matematice. Considerînd un model dinamic al dezvoltării/modernizării rețelelor electrice, cu ajutorul intervențiilor interactive, bazate pe metode euristice, chiar și acele restricții care sînt greu de cuantificat matematic pot fi luate în seamă. Mai mult, aceste criterii/restricții pot fi introduse treptat, lucru ce simplifică foarte mult programul de calcul.

Aceasta se bazează pe un model de abordare dinamică a problemei. Metodologia permite considerarea a diferite ipoteze (de cost, de accesibilitate, de impact asupra mediului etc.), în diverse stadii de procesare/decizie. În final, va fi obținută soluția optimă, care va ține cont de toate condițiile/restricțiile reale, întâlnite în diferite cazuri concrete de modernizare.

5.3.3.1. Program pentru determinarea arhitecturii optime a rețelelor electrice radiale

Prezentare generală

PARED este un program de calcul realizat de autori în limbajul de programare MatLab, pentru determinarea arhitecturii optime a rețelelor de distribuție și care are multiple facilități de utilizare interactivă. Din punctul de vedere al concepției și realizării, este un program foarte flexibil, permițând introducerea a diferite considerente (de cost, accesibilitate etc.), în diferite etape de procesare, răspunzând astfel cerințelor de optimizare multicriterială.

Problema optimizării se pune în special în cazul traseelor lungi, ce străbat zone întinse. În orașe, numărul mare de restricții impuse reduce considerabil variantele traseului ce trebuie urmat.

Programul lucrează cu hărți scanate ale diferitelor suprafețe (Fig. 5.17) și cu informații spațiale (Fig. 5.18). Hărțile trebuie scanate iar apoi pot fi manipulate și salvate în fișiere cu extensia *.jpg, *.bmp, *.tiff.

Toate formele geometrice construite cu ajutorul informațiilor spațiale se referă la noduri, linii și suprafețe. Un nod este înregistrat prin intermediul unor coordonate X, Y și opțional Z și este folosit la reprezentarea transformatoarelor, barelor de MT/JT, întrerupătoare etc. O linie este reprezentată printr-un element geometric ce face legătura între două noduri, permițând și noduri intermediare, și poate fi folosită să descrie linii electrice de distribuție. O suprafață este determinată de două sau mai multe linii care împreună formează un poligon închis. Păduri, lacuri, parcuri, porțiuni din rețele electrice sau suprafețe ce cuprind clădiri pot fi descrise de acest gen de poligon.

Nodurile cuprind informații cu privire la coordonatele asociate cu acestea. Liniile nu sînt definite în termeni de coordonate geografice. Acestea sînt definite prin indicarea nodurilor topologice. Suprafețele sînt definite de liniile ce formează suprafața respectivă. Toate aceste forme geometrice sînt create și salvate automat.




Fig. 5.17. Document sub formă de hartă scanată




Fig. 5. 18. Document construit cu ajutorul informațiilor spațiale

Obiectivul programului este determinarea traseului optim și dimensionarea unei rețele radiale de distribuție, cunoscând poziția sursei de alimentare, precum și pozițiile geografice ale consumatorilor.

Pentru concretizarea unor soluții, programul dă posibilitate utilizatorului de a "sugera" varianta respectivă, prin indicarea suplimentară a altor puncte de reper, prin care să treacă rețeaua (de-a lungul cailor de comunicații etc). Pe baza acestor date, programul determină: arhitectura rețelei de lungime (cost) minimă, lungimea (costul) total al rețelei, lungimea (costul) între două repere și altele. Față de această variantă, considerată principală, utilizatorul poate interveni introducând:

- modificarea costurilor unor trasee;
- modificarea/introducerea coordonatelor unor puncte din amplasament;
- modificarea poziției sursei de alimentare;
- interzicerea/forțarea unor legături etc.

Utilizatorul poate proceda la compararea mai multor soluții, corespunzând la diverse variante, în final putându-se alege cea mai convenabilă soluție, pe baza ipotezelor făcute, deși se pleacă inițial de la o rețea determinată doar pe baza unor amplasamente geografice. Astfel, în final se poate obține configurația optimă a rețelei de distribuție din zona respectivă, rețea care ține seama de toate condițiile (restricțiile) reale întâlnite în activitatea curentă de planificare.

Meniurile programului

Programul **PARED** determină rețeaua radială de lungime minimă (cost) care pleacă dintr-un punct dat și alimentează un număr de consumatori a căror poziționare este cunoscută. Programul este realizat la nivel profesional și permite o utilizare ușoară.

Opțiunile meniului principal sînt, Fig. 5.19:

- **EDITARE** - încarcă datele legate de rețeaua care urmează să fie optimizată;
- **OPȚIUNI** – introduce sau modifică nodul de start;
- **AFIȘARE REȚEA** - afișează rețeaua optimizată;
- **ACTUALIZARE** - modifică rețeaua curentă;
- **SALVARE DATE** – salvează rezultatele procesului de optimizare;
- **AFIȘARE REZULTATE** – afișează rezultatele procesului de optimizare;
- **HELP** - oferă informații despre program;
- **IEȘIRE PROGRAM** - părăsirea aplicației.




Fig. 5.19. Meniul principal al programului PARED

5.3.3.2. Exemplu de aplicație

Problema optimizării se pune în special în cazul traseelor rurale, ce străbat zone întinse. În orașe, numărul mare de restricții impuse reduce considerabil variantele traseului ce trebuie urmat.

S-a considerat o porțiune a unei rețele rurale de 20 kV. Traseul rețelei a fost modificat prin adoptarea unor strategii cum ar fi: linie ce urmează un traseu fără restricții, linie ce urmărește căile de comunicații (drumuri) și cea de-a treia variantă - combinație a primelor două.

Alegerea traseului în lungul căilor de comunicații (drumuri naționale sau județene) implică un consum de material mai mare (investiții mai mari), dar există și o serie de avantaje cum ar fi: accesul ușor al echipelor de montaj și al utilajelor în faza de construcție a liniei precum și al echipelor de intervenție și întreținere în faza de exploatare. Valoarea cheltuielilor de întreținere și exploatare reprezintă cca 4,5% din valoarea liniei. Trebuie luată în considerare în acest caz și evoluția traseelor căilor de comunicații.

Varianta liniei care urmează un traseu fără restricții duce la o reducere a costului materialelor necesare construcției liniei. Totuși, accesul la linie în unele zone se va face

greu datorită terenurilor impracticabile în condiții meteorologice nefavorabile (polei, zăpadă etc), traseul neținând seama de aceste porțiuni de teren în care accesul este greu atât în faza de construcție a liniei cât și în faza de exploatare. Astfel, pentru această variantă cheltuielile de întreținere și exploatare reprezintă cca 6,5% din valoarea liniei, [Cârțină 03/5]. Ingreunarea accesului la rețea, pe lângă faptul că duce la o creștere a cheltuielilor de exploatare și întreținere, determină și o scădere a continuității în alimentarea cu energie electrică. Nu poate fi neglijat nici faptul că în unele cazuri trebuie plătite despăgubiri datorită traversării unor terenuri agricole particulare, ceea ce duce evident la majorarea costurilor de investiție. În cazul în care linia traversează o suprafață de teren cu sol insuficient de rezistent (o mlaștină, de exemplu) este necesară realizarea unor fundații speciale ceea ce implică o suplimentare a costurilor investiției.

O variantă ce ar putea realiza minimizarea investițiilor este realizarea unui traseu combinat. Rețeaua electrică va fi realizată pe traseu fără restricții în zonele unde este permis acest lucru, iar în unele porțiuni va urmări traseul căilor de comunicații. Alte criterii de optimizare pot fi considerate de către expert într-o manieră interactivă, folosind disponibilitățile programului, așa cum am precizat în cele de mai sus.

În Fig. 5.20 este reprezentată amplasarea în teren a sursei și a consumatorilor. Cunoscând aceste puncte, s-au imaginat trei itinerarii distincte ale rețelei de 20 kV conforme celor trei variante prezentate deja la începutul subcapitolului, Fig. 5.21, 5.22 și 5.23.




Fig. 5.20. Amplasarea în teren a consumatorilor




Fig. 5.21. Schema de rețea fără considerarea restricțiilor



Fig. 5.22. Schema de rețea ce urmărește căile de comunicații




Fig. 5.23. Schema de rețea în variantă intermediară




Fig. 5.24. Detaliu cu introducerea unor puncte suplimentare prin care să treacă rețeaua

În Fig. 5.24 este prezentat un detaliu al zonei prin care trebuie să treacă rețeaua electrică, în cursul procesului dinamic de optimizare, în care se poate vedea modul în care sînt introduse, cu ajutorul mouse-ului punctele de reper suplimentare prin care poate să treacă rețeaua.

Trebuie menționat, de asemenea, că alegerea traseului unei linii electrice implică un studiu amănunțit al zonei respective (a solului, a formelor de relief etc) pentru a avea o situație cît mai clară a terenului respectiv, a restricțiilor ce se impun precum și o analiză a prognozei consumului de energie a zonei ce este deservită de rețeaua respectivă. În mod normal ar trebui să se analizeze un număr cît mai mare de variante plauzibile de trasee ce țin cont de situația reală din teren pentru a se face în final o alegere cît mai realistă a traseului optim al rețelei.

5.4. Coordonarea mijloacelor de reglaj prin tehnici neuro-fuzzy

5.4.1. Importanța coordonării mijloacelor de reglaj

În cele ce urmează se prezintă o tehnică de optimizare multiobiectiv privind coordonarea mijloacelor de reglaj tensiune-putere reactivă, UQ, în cazul stațiilor de distribuție. Plecînd de la prognoza puterilor cerute în nodurile de MT, se tratează dispecerizarea optimă a comutatoarelor de ploturi ale transformatoarelor, (CP), și a comutării treptelor bateriilor de condensatoare, (BC), astfel încît tensiunea în nod să fie cît mai aproape de o valoare de referință, iar circulația de puteri reactive să fie cît mai redusă. Soluționarea problemei se face prin programare dinamică fuzzy, PDF [Lu 97], [Cârțină 99/1-2].

Reglajul tensiune-putere reactivă, UQ, în ultimii ani, este o problemă care preocupă mulți specialiști. În rețelele de transport și distribuție, reglajul UQ este, în general, tratat împreună cu circulația optimă de puteri. Abordările au fost numeroase și s-au făcut folosind diverse metode: programare dinamică, programare neliniară, Rețele neuronale artificiale, Sisteme expert, Algoritmi genetici etc. Asigurarea unui nivel optimal de tensiune într-o rețea electrică constituie, așa cum am mai precizat anterior, o problemă de calitate, dar și o problemă de siguranță în funcționare. Mai mult, tensiunea în noduri este considerată unul dintre indicatorii de performanță cei mai importanți pentru securitatea și calitatea funcționării rețelei electrice.

În ceea ce privește reglajul UQ în stațiile de distribuție, acesta este mai puțin analizat, fiind tratat în cadrul abordării problemei pe ansamblul rețelei de transport. Obiectivul reglajului UQ în stațiile de distribuție este controlul tensiunii pe barele de MT și a circulației de putere reactivă prin transformator, folosind ploturile

transformatorului și bateriilor de condensatoare din stație. Deoarece modificarea treptei bateriei de condensatoare afectează nivelul tensiunii, poate apărea necesitatea modificării plotului de funcționare al transformatorului. În această situație este, deci, esențială o coordonare a comutării ploturilor cu modificarea puterii bateriilor de condensatoare din stație.

Pentru rezolvarea acestei probleme, în cazul de față se utilizează o tehnică neuro-fuzzy.

Proгноza tensiunii pe bara IT și a puterilor pe bara MT din stația de distribuție se realizează cu ajutorul unor rețele neuronale artificiale, (RNA), iar soluțiile optime se determină pe baza unei funcții multiobiectiv de tip fuzzy.

5.4.2. Coordonarea mijloacelor de reglaj prin tehnici neuro-fuzzy

Pentru rezolvarea problemei reglajului UQ în stațiile de distribuție, se apelează la o optimizare multiobiectiv, bazată pe programarea dinamică fuzzy, PDF, soluția optimă trebuind să verifice și restricțiile de inegalitate ale modelului. Scopul principal este îmbunătățirea nivelului tensiunii pe bara de MT și, în același timp, reducerea circulației de putere reactivă prin transformatorul/transformatoarele stației. Pentru atingerea acestui obiectiv se folosesc CP al transformatorului și BC reglabilă, instalată pe bara MT. Strategia de reglare UQ în stațiile de distribuție implică, pentru ziua următoare, prognoza tensiunii pe bara IT, precum și prognoza de putere activă și reactivă pe bara MT. În plus, trebuie avut în vedere un număr de restricții practice, dintre care cea mai importantă se referă la numărul maxim de comutări/zi pentru CP și BC [Minakawa 93], [Hsu 92], [Lu 97].

Strategia pentru prevenirea manevrelor inutile ale CP și BC se bazează pe prognoza puterilor reactive viitoare. Astfel, acțiunile de reglaj trebuie condiționate de tendințele de evoluție ale sarcinii în viitorul imediat. Se apreciază că o comandă de comutare CP - BC n-ar trebui acceptată, dacă o operație inversă s-ar impune, să zicem, în 30 de minute. Prognoza de putere activă și reactivă pentru bara de MT se face cu o zi în avans. Pentru aceasta se poate utiliza o rețea neuronală artificială, RNA, adaptivă, cu antrenare on-line, care asigură o prognoză destul de robustă și de exactă. În cazul de față s-a folosit o RNA cu 31 neuroni pe stratul de intrare, 10 neuroni pe stratul ascuns și un neuron pe stratul de ieșire [Cârțină 99/1-2]. Ca date de intrare s-au folosit temperaturile medii pe ultimele 3 zile și pe ultimele 3 ore, precum și sarcinile reprezentative din ultimele 8 zile.

Dacă, în cadrul reglării UQ, CP și BC sînt acționate independent, comutarea BC poate afecta tensiunea barei secundare și, prin urmare, mișcările CP pot deveni foarte frecvente, rezultînd o reducere a speranței de viață a acestuia și, implicit, o creștere a costului de mentenanță. În consecință, se impune ca esențială coordonarea comenzilor CP și BC. O abordare interesantă este aceea în care se optează pentru o

programare dinamică fuzzy (PDF), considerînd numărul maxim de comutări admis pe zi pentru CP și BC. În cadrul acesteia se urmărește determinarea unei strategii optime privind comutările CP și BC, astfel încît tensiunea pe bara MT să fie păstrată cît mai aproape de valoarea de referință, factorul de putere să fie cît mai mare, iar numărul de manevre pe zi pentru CP și BC să nu depășească limitele impuse anterior.

În această situație, ca dealtfel în cele mai multe cazuri de optimizare multiobiectiv, MO, funcțiile obiectiv sînt noncomensurabile și nu pot fi reduse la una singură. În general, este imposibil să se obțină o soluție optimală, pentru care toate funcțiile obiectiv să atingă extremul. Cele mai multe tehnici, folosite în asemenea cazuri, au la bază conceptul de noninferioritate (cunoscut și sub numele de optimalitatea Pareto). Pentru a evita o parte din dificultățile menționate mai sus, rezolvarea problemei se poate face în acest caz prin PDF, care permite înlocuirea mai multor funcții obiectiv, printr-o singură funcție obiectiv de tip fuzzy.

Reamintim că, mulțimile fuzzy modelează posibilitatea de apartenență la un concept semantic, numit funcție de apartenență. Valoarea acesteia indică gradul de apartenență a elementului x la A sau gradul de încredere că elementul x are proprietatea asociată semantic mulțimii respective. Funcțiile de apartenență pot avea aliuri asemănătoare funcțiilor de distribuție utilizate în teoria probabilităților, forma respectivă fiind stabilită de expert, pentru fiecare caz concret, pe baza experienței, fără pretenție de formulare matematică exactă.

Plecînd de la prognoza consumului de putere și al tensiunii primare, pentru următoarele 24 h, cu ajutorul unei RNA, statutul CP și BC se determină oră de oră, astfel încît tensiunea pe barele de MT să fie cît mai apropiată de valoarea de referință, iar tranzitul de putere reactivă prin transformator să fie cît mai mic posibil. Din practica dispecerilor se impune: $\cos \varphi \geq 0,8$, $\Delta U_2 \leq 5\%U_n$, iar numărul de comutări pe zi pentru CP și BC să nu depășească 30, ($N_{CP} \leq 30$), respectiv, 6, ($N_{BC} \leq 6$) [Lu 97], [Cârțină 99/1-2].

Dacă se notează variabilele de control pentru BC (BC1, BC2), respectiv, CP, cu

$$\begin{aligned} X1_i (X2_i) &= 0 \text{ (BC1 (BC2) deconectată); } i = h = 1, 2, \dots, N = 24; \\ X1_i (X2_i) &= 1 \text{ (BC1 (BC2) conectată); } i = h = 1, 2, \dots, N = 24; \\ CP_i &= -9, \dots, 0, \dots, 9; \quad i = h = 1, 2, \dots, N = 24, \\ \Delta U_2 &= |\Delta U_2|, \end{aligned}$$

obiectivul fixat în cele de mai sus se traduce prin funcția:

$$F = \sum_{i=1}^{N=24} \mu_{\Delta U_2} + \sum_{i=1}^{N=24} \mu_{\cos \varphi} = F_1 + F_2 \rightarrow \max ! \quad (5.12)$$

a cărei maximizare se face în prezența restricțiilor:

$$N_{CP} = \sum_{i=1}^N |CP_i - CP_{i-1}| \leq 30 \quad (5.13)$$

$$N_{BC1} = \sum_{i=1}^N |X1_i - X1_{i-1}| \leq 6; \quad N_{BC2} = \sum_{i=1}^N |X2_i - X2_{i-1}| \leq 6 \quad (5.14)$$

$$U_2^{\min} \leq U_2 \leq U_2^{\max}; \quad 0,8 \leq \cos \varphi \leq 1 \quad (5.15)$$

În literatură limitele tensiunii și ale factorului de putere sînt tratate cel mai adesea ca restricții, rel. (5.15). Aceasta face ca mărimile respective să se miște între limitele respective maxime, după implementarea procedurii de optimizare [Hsiao 94]. Introducerea unei funcții obiectiv de tipul (5.12) evită un asemenea neajuns. Pentru funcțiile de apartenență privind abaterile tensiunii, respectiv, factorul de putere, considerăm formele liniare, prezentate în Fig.5.25 respectiv, Fig.5.26.




Fig. 5.25. Funcția de apartenență a abaterii tensiunii




Fig. 5.26. Funcția de apartenență pentru $\cos \varphi$

În funcția obiectiv (5.12), termenul F_1 cuantifică dorința de menținere a tensiunii pe bara de MT cât mai aproape de valoarea de referință, iar termenul F_2 , dorința ca factorul de putere pentru transformator să fie cât mai mare posibil. Pe baza modelului de optimizare (5.12) – (5.15) se pot determina valorile optime de control $X1_i$, $X2_i$ și CP_i . Pentru rezolvarea problemei de optimizare respective aplicăm principiul programării dinamice, relația de recurență pentru a ajunge la starea (h, Q_{BC}) , la ora h , avînd forma:

$$F(h, Q_{BC}) = \max_{X_i} \{F_h(h, X_i) + F(h-1, Q_{BC})\} \quad (5.16)$$

unde:

$F(h, Q_{BC})$ – valoarea totală a funcției (5.12) pentru a ajunge în starea (h, Q_{BC}) ;
 $F_h(h, X_i)$ – valoarea funcției (5.12) pentru trecerea de la starea $(h-1, Q_{BC})$, la starea (h, Q_{BC}) .

Considerînd în fiecare etapă a programării dinamice fuzzy raportul de transformare ideal (KI), pentru a obține tensiunea dorită pe bara MT, se determină raportul de transformare real (KR), prin rotunjirea variabilei la valoarea întreagă superioară și interioară a CP_i .

Dacă în fiecare etapă a PDF se au în vedere două posibilități pentru fiecare din cele 2 trepte ale BC, conectată/deconectată, rezultă un număr de 4 combinații posibile pentru fiecare din cele 24 h.




Fig. 5.27. Stație de distribuție

Metoda PDF prezentată a fost testată pe mai multe cazuri reale. Pentru exemplificare, se prezintă în continuare cazul stației de distribuție din Fig.5.27, unde BC este compusă din 2 trepte a câte 1, 2 MVAR [Cârțină 99/1-2]. Pe ansamblul celor 24 h se constată 2 comutări de ploturi ($N_{CP} = 2$) și câte 4 comutări ($N_{BC1} = 4$), respectiv, 2 comutări ($N_{BC2} = 2$), pentru treapta 1, respectiv, treapta 2 ale BC. Valoarea totală a funcției obiectiv pentru soluția optimă este în cazul BC reglabilă: $F = F_1 + F_2 = 40,96$, Tabelul 5.12, față de $F = F_1 + F_2 = 40,55$, în cazul BC cu o singură treaptă. Avantajul cel mai mare realizat în cazul BC cu 2 trepte este diminuarea semnificativă a pierderilor de putere în transformator.

Tabelul 5.12. Rezultatele numerice pentru cazul BC cu una și două trepte, Fig. 5.27

h	P ₂ [MW]	Q ₂ [MVar]	Q _{BC} = 2,4 MVar				Q _{BC} = 2 x 1,2 MVar			
			CP	X	F ₁	F ₂	X1	X2	F ₁	F ₂
1	3,23	0,67	2	0	0,88	0,92	0	0	0,88	0,92
2	3,01	0,78	2	0	1,76	1,62	0	0	1,76	1,62
3	2,87	0,84	2	0	2,64	2,32	0	0	2,64	2,32
4	2,79	0,87	2	0	3,53	3,02	0	0	3,53	3,02
5	2,74	0,90	2	0	4,42	3,72	0	0	4,42	3,72
6	2,84	1,20	2	0	5,34	4,22	1	0	5,22	4,72
7	3,63	1,39	2	0	6,28	4,73	1	0	6,02	5,64
8	5,35	1,56	2	0	7,22	5,43	1	0	6,82	6,56
9	8,93	2,59	2	1	8,12	6,41	1	1	7,62	7,48
10	11,11	3,83	2	1	9,08	7,39	1	1	8,54	8,44
11	12,40	4,54	1	1	9,78	8,34	1	1	9,24	9,38
12	12,95	4,82	1	1	10,48	9,29	1	1	9,94	10,33
13	12,45	4,58	1	1	11,18	10,24	1	1	10,64	11,28
14	12,04	4,31	1	0	12,03	10,84	0	1	11,39	12,08
15	12,42	4,46	1	1	12,73	11,80	0	1	12,19	12,88
16	12,27	4,48	1	1	13,43	12,76	0	1	12,99	13,68
17	11,89	4,41	1	1	14,03	13,74	1	1	13,59	14,60
18	10,15	3,65	2	1	14,95	14,72	1	1	14,49	15,52
19	9,04	3,12	2	1	15,85	15,70	1	1	15,39	16,44
20	7,87	2,49	2	1	16,67	16,68	0	1	16,34	17,36
21	7,12	2,04	2	0	17,65	17,40	0	1	17,24	18,28
22	5,78	1,09	2	0	18,55	18,36	0	0	18,14	19,18
23	4,33	0,94	2	0	19,41	19,32	0	0	19,00	20,14
24	3,71	0,65	2	0	20,27	20,28	0	0	19,86	21,10

5.5. Optimizarea amplasării surselor de putere reactivă

5.5.1. Formularea problemei de optimizare

Optimizarea planificării surselor reactive în rețelele de distribuție are în vedere reducerea pierderilor și îmbunătățirea profilului tensiunilor. Obișnuit, problema optimizării surselor reactive se împarte în două subprobleme: una operațională și alta de investiție. În prima etapă, sursele reactive disponibile sunt dispuse optimal, după criteriul costului de exploatare minim, iar în cea de-a doua, se instalează surse noi de putere reactivă, pe baza criteriului cost total minim (exploatare, investiție) [Lee 95].

Problema optimizării surselor reactive în rețelele de distribuție continuă să fie una dintre cele mai cercetate. Obiectivul cel mai frecvent l-a constituit minimizarea

cheltuielilor totale actualizate (CTA). S-a constatat că tehnicile de Inteligență artificială (IA) (RNA, LF, SE, AG) oferă și în acest domeniu oportunități deosebite în abordare și rezolvare, obținând soluții mai sigure și mai flexibile.

Cel mai adesea tehnicile de rezolvare depind esențial de modelul matematic al problemei de optimizare (de gradul de disponibilitate al unor date). De aceea, în cele ce urmează, vom da o atenție deosebită modelului matematic, prezentând unul din cele mai complete posibil, rezolvarea fiind făcută cu ajutorul Algoritmilor genetici (AG). Acest model are în vedere modul de amplasare al bateriilor de condensatoare pe fiderii de medie tensiune, luând în considerare și restricțiile impuse de comutarea și funcționarea condensatoarelor. Acest lucru este foarte util societăților de electricitate care instalează cantități mari de baterii de condensatoare în RD. În vederea optimizării amplasării și duratei de funcționare a acestor baterii, s-a considerat întregul sistem – fiderii, transformatorul din stația de transformare care alimentează acești fideri și sistemul de transport echivalent. Soluționarea problemelor complexe s-a făcut utilizând tehnica AG. Pentru demonstrarea eficienței acestei metode, se prezintă un exemplu practic de optimizare al amplasării bateriilor de condensatoare pe câțiva fideri de MT din societatea de electricitate din Israel, IEC [Kalyuzhny 98].

În rețelele de distribuție se instalează, de obicei, baterii de condensatoare, (BC), în stațiile de transformare (ST, pe partea de MT), (BCS), pe stâlpii liniilor electrice aeriene (LEA) de MT, în puncte de alimentare și în posturile de transformare (pe parte de MT și JT). Amplasarea bateriilor de condensatoare pe stâlpii (BCS) liniilor aeriene de MT reprezintă o practică curentă în rețelele de distribuție de MT din societățile de electricitate din continentul american și în special din SUA și Canada. În ultimii ani și în RD aeriene din IEC - Israel se instalează BCS, acestea fiind foarte eficiente din punct de vedere economic.

Determinarea amplasamentului optim al BCS numai din punct de vedere al reducerii pierderilor, dar neluând în considerație fenomenele tranzitorii care pot apărea în momentul comutării BCS în vecinătatea altor BCS sau din apropierea unei BC instalată pe barele de MT al unei stații (ST), nu este corectă, mai ales în RD moderne în care sînt instalate multe BC și BCS. După cum se știe, comutarea unei BC în vecinătatea altor BC poate conduce la apariția unor curenți tranzitorii mari și periculoși, curenți care pot cauza defecte serioase în condensatoare, în echipamentul de comutare al bateriei și arderea siguranțelor de protecție a condensatoarelor.

S-a demonstrat că, în rețelele de MT urbane, construite în exclusivitate în cablu subteran, beneficiile obținute prin instalarea BC în PT nu rezultă din reducerile de pierderi, ci din creșterea rezervei de putere în transformatoarele din ST. Acest avantaj se poate fructifica mai ales în zonele urbane dense, unde nu mai există posibilități de extinderi în stațiile existente și uneori nu există loc pentru construcția de stații și posturi noi. Deci, prin instalarea masivă de baterii de condensatoare – BC și BCS – se pot amîna investiții scumpe în stații noi [Kalyuzhny 98].

În cele ce urmează se prezintă metoda de amplasare optimă a BCS pe fiderii de MT, luând în considerare influența acestora asupra întregului sistem. În plus, se iau în considerare următoarele restricții, fără de care optimizarea nu poate fi completă:

- Restricții legate de durata de funcționare a BC și BCS;
- Restricții legate de păstrarea unui nivel acceptabil de tensiuni de-a lungul fiderilor;
- Restricții dictate de fenomenele tranzitorii care apar în timpul comutării BCS.

Intrucât rezolvarea acestor probleme reprezintă o problemă de optimizare foarte complexă, rezolvarea ei va fi soluționată aplicând tehnica Algoritmilor genetici, tehnică care rezolvă, astfel, cu succes probleme de optimizare complexă.

5.5.2. Modelul matematic

5.5.2.1. Beneficiile instalării bateriilor de condensatoare

Schema utilizată pentru calculul beneficiilor și optimizarea BCS și BC este prezentată în Fig. 5.28.

Pentru calculul reducerilor de pierderi de energie pe elementele sistemului de distribuție se folosesc curbele clasate de sarcină anuală ale stației de transformare și ale fiecărui transformator din ST. Aceste curbe se pot aproxima prin funcții treaptă, obținute prin divizarea anului în n intervale de timp, în care nivelul sarcinii este constant.

Pentru modelul de RD din Fig. 5.28, considerăm o BC de mărime Q_{BC} [kVAr], instalată în ST și k baterii de tip BCS, instalate pe fiderii rețelei alimentați din Trafo 2 al stației considerate. Fiecare BCS este caracterizată prin mărimea Q_j [kVAr], aparținând celor 2 – 3 valori standardizate, prin costul C_j și locul acesteia, (f_j, l_j) , unde f_j este numărul fiderului iar l_j este numărul tronsonului de fider, pe care este montată bateria respectivă.

Beneficiul datorat creșterii rezervei de putere în sistemul de distribuție

În primul rând vom calcula expresia creșterii de putere în sistem (practic în stația de transformare), obținută în urma instalării bateriilor de condensatoare BC și BCS, pe partea de medie tensiune a stației ST.




Fig. 5.28. Modelul sistemului de distribuție pentru optimizarea amplasării bateriilor de condensatoare

Considerăm că sarcina maximă pe partea de IT a transformatorului Trafo 2, fără compensare, este $\underline{S}_{1 \max} = P_{1 \max} + jQ_{1 \max}$, iar sarcina maximă a acestui transformator, pe partea de MT, fără compensare, este $\underline{S}_{2 \max} = P_{2 \max} + jQ_{2 \max}$.

Prin instalarea unei BC pe barele de MT ale transformatorului Trafo 2 și a câtorva BCS, pe fiderii alimentați de acesta, încărcarea transformatorului va scădea. Noua valoare a încărcării transformatorului pe partea de MT, $\underline{S}_{2 \max}^{comp}$, este dată de :

$$\underline{S}_{2 \max}^{comp} = P_{2 \max} - \Delta P_{L \max}^{feed} + j(Q_{2 \max} - \Delta Q_{comp}) \quad (5.17)$$

unde:

$\Delta P_{L \max}^{feed}$ - reducerea de putere activă la vîrf de sarcină în sistemul de distribuție de MT ca urmare a instalării BCS pe fideri;

ΔQ_{comp} - reducerea totală de putere reactivă pe partea secundară a Trafo 2, ca urmare a instalării bateriilor de condensatoare în stație și pe fideri.

Rezultă că mărimea sarcinii suplimentare care poate fi alimentată de transformatorul respectiv va fi:

$$\Delta S_{2\max} = g \cdot (P_{2\max} + jQ_{2\max}) \quad (5.18)$$

Coeficientul de creștere a sarcinii (în u.r.), din expresia (5.18), se determină din următoarea ecuație [Kalyuzhny 98], [Zisman 99/3]:

$$\left(P_{2gc} + R_t \cdot \frac{(P_{2gc}^2 + Q_{2gc}^2)}{U_2^2} \right)^2 + \left(Q_{2gc} + X_t \cdot \frac{(P_{2gc}^2 + Q_{2gc}^2)}{U_2^2} \right)^2 = S_{1\max}^2 \quad (5.19)$$

unde:

$$P_{2gc} = (1 + g) \cdot P_{2\max} - \Delta P_{L\max}^{feed} + \Delta P_{FE} \cdot \left(\frac{U_2}{U_{2n}} \right)^2 \quad (5.20)$$

$$Q_{2gc} = (1 + g) \cdot Q_{2\max} - \Delta Q_{comp} + \Delta Q_{FE} \cdot \left(\frac{U_2}{U_{2n}} \right)^2$$

iar:

R_t și X_t - rezistența, respectiv, reactanța transformatorului din ST;

ΔP_{FE} și ΔQ_{FE} - pierderile active, respectiv, reactive în fierul transformatorului;

U_2 - tensiunea pe barele de MT ale Trafo 2 în regim de vîrf de sarcină;

U_{2n} - tensiunea nominală pe partea secundară a transformatorului.

Această sarcină suplimentară reprezintă de fapt creșterea rezervei de putere a sistemului, ΔS_{CR} . Valoarea lui ΔS_{CR} se determină în funcție de coeficientul de creștere a sarcinii, g , din expresiile următoare:

$$\Delta S_{CR} = \sqrt{\left(P_{2g} + R_t \cdot \frac{(P_{2g}^2 + Q_{2g}^2)}{U_2^2} \right)^2 + \left(Q_{2g} + X_t \cdot \frac{(P_{2g}^2 + Q_{2g}^2)}{U_2^2} \right)^2} - S_{1\max} \quad (5.21)$$

unde:

$$P_{2g} = (1 + g) \cdot P_{2\max} + \Delta P_{FE} \cdot \left(\frac{U_2}{U_{2n}} \right)^2$$

$$Q_{2g} = (1 + g) \cdot Q_{2\max} + \Delta Q_{FE} \cdot \left(\frac{U_2}{U_{2n}} \right)^2$$
(5.22)

Beneficiul anual care se obține datorită creșterii rezervei de putere, C_{CR} se determină din expresia:

$$C_{CR} = \Delta S_{CR} \cdot c_{CR}$$
(5.23)

unde: c_{CR} - costul anual al creșterii rezervei de putere, în [\$/kVA].

Beneficiul datorat reducerii pierderilor de putere și energie

Costul reducerii pierderilor de putere la vârful de sarcină, C_{PL} , este dat de relația:

$$C_{PL} = (\Delta P_{L\max} - \Delta P_{L\max}^{comp}) \cdot c_L$$
(5.24)

unde:

$\Delta P_{L\max}$ - pierderile totale de putere în sistemul de distribuție, în transformatorul în stație și în sistemul echivalent de IT, fără compensarea puterii reactive;

$\Delta P_{L\max}^{comp}$ - pierderile totale de putere în sistemul de distribuție, în transformatorul și în sistemul echivalent de IT, luând în considerație compensarea puterii reactive prin bateriile BC și BCS;

c_L - costul anual al unui kW de pierderi de putere, la vârful de sarcină, [\$/kW].

Reducerea anuală de energie depinde de duratele de funcționare anuală a bateriilor de condensatoare. Aceste durate depind de mijloacele de control ale BC și BCS: în funcție de tensiune, de puterea reactivă, de timp etc. Presupunem că BC din ST este controlată de un dispozitiv automat de reglare a puterii reactive, iar BCS, de pe fideri sînt controlate de dispozitive automate bazate pe timp.

Pentru evaluarea soluțiilor posibile, se presupune că toate BCS sînt comutate în conformitate cu fiecare nivel de sarcină considerat. Cu alte cuvinte, pentru fiecare

nivel de sarcină, au fost considerate următoarele durate de funcționare (după modul de comutare):

- Toate bateriile BC și BCS sînt deconectate;
- Toate BCS sînt conectate, iar BC sînt deconectate;
- Toate bateriile BC și BCS sînt conectate.

Pentru determinarea duratelor optime de funcționare ale bateriilor BC și BCS, care conduc la reducerea maximă de energie pentru nivelul i de sarcină, este necesar să calculăm reducerea maximă pentru fiecare din cele trei moduri de comutare. Reducerea maximă de pierdere, pentru fiecare nivel de sarcină i , se obține prin calculul valorii maxime a expresiei:

$$\Delta P_{Li}^{\max} = \max \{0, \Delta P_{Li}^2 - \Delta P_{Li}^1, \Delta P_{Li}^3 - \Delta P_{Li}^1\} \quad (5.25)$$

unde:

$\Delta P_{Li}^1, \Delta P_{Li}^2, \Delta P_{Li}^3$ reprezintă pierderile totale de putere în sistem, pentru nivelul de sarcină i și modurile de comutare al bateriilor descrise mai sus.

Durata de funcționare optimă pentru nivelul de sarcină i și amplasamentul considerat al unei baterii BCS este aceea durată care conduce la reducerea maximă de putere $\Delta P_{Li}^{\max}$. Beneficiile care rezultă ca urmare a reducerii anuale a pierderilor de energie obținută de o durată de funcționare optimă, și o amplasare oarecare a bateriilor BCS, C_{EL} se determină cu relația:

$$C_{EL} = c_E \cdot \sum_{i=1}^n \Delta P_{Li}^{\max} \cdot T_i \quad (5.26)$$

unde:

c_E - costul unui kWh de energie pierdută, [\$/kWh];

T_i - durata de timp a nivelului de sarcină i , [h].

Calculul beneficiului total

Cunoscînd beneficiile datorate creșterii rezervei de putere, C_{CR} , a reducerii pierderilor de putere și energie, C_{PL} și C_{EL} , se poate calcula beneficiul total, care se poate obține în urma instalării bateriilor de condensatoare în stația de transformare și pe fideri, C_{TOTAL} :

$$C_{TOTAL} = C_{CR} + C_{PL} + C_{EL} - C_{BC} - \sum_{j=1}^k C_j \quad (5.27)$$

unde:

C_{BC} - costul anual de exploatare al bateriei de condensatoare, BC, instalată în stația de transformare;

C_j - costul anual al unei baterii BCS, instalată pe fider de MT.

5.5.2.2. Restricții în amplasarea bateriilor de condensatoare

Pentru determinarea finală a puterii și locului optim de amplasare a BCS se vor lua în considerare restricții rezultate din variația tensiunilor în nodurile fiderilor și de fenomenele tranzitorii care pot apare în timpul comutării condensatoarelor.

Restricții de tensiune

Restricțiile rezultate din variația tensiunii se vor lua în considerare prin specificarea limitelor superioare și inferioare ale tensiunilor admise în nodurile RD de MT. Pentru un nod oarecare m din rețea și un nivel de sarcină, i , restricțiile de tensiune se exprimă în felul următor:

$$U_{MIN}^2 \leq U_{mi}^2 \leq U_{MAX}^2 \quad m = 1, \dots, m, \quad i = 1, \dots, n \quad (5.28)$$

unde:

U_{MIN} și U_{MAX} - tensiunea minimă, respectiv, maximă admisă;

m - numărul de noduri din RD de MT;

n - nivelul de sarcină n .

Restricții de comutare

O baterie de condensatoare montată pe stîlpul unei linii aeriene de MT trebuie să fie astfel amplasată, încît să prevină apariția curenților de comutare periculoși, cauzati de prezența altor baterii vecine.

Amplitudinea curentului tranzitoriu care apare în momentul conectării unei BCS, trebuie să fie mai mică decît amplitudinea curentului maxim admis, $I_{max j}$, pentru condensatoarele și echipamentul de comutare al bateriei considerate (j).

Altă restricție impusă amplasării BCS se referă la valoarea I^2t , care apare în momentul conectării bateriei și care nu trebuie să depășească valoarea $I^2t_{\max j}$ pe care siguranțele bateriei îl pot suporta fără a se topi.

În cazul de față, calculul curentului de conectare al BCS se va efectua cu o metodă simplificată. Această metodă se bazează pe ipoteza că, în momentul conectării unei BCS, toate celelalte baterii vecine sunt deja conectate. Cu această ipoteză, curentul de conectare al unei BCS se calculează utilizând circuitul echivalent de conectare a condensatoarelor, cunoscut sub denumirea "capacitor back-to-back switching"




Fig. 5.29. Circuitul echivalent pentru calculul curenților de conectare

(a) circuit echivalent "back-to-back switching";

(b) circuitul pentru determinarea parametrilor

Curentul de conectare "back-to-back" $I_{sw}(t)$ al unei baterii de condensatoare având capacitatea C_j , într-un circuit echivalent având capacitatea C_{tot} , este dat de expresia:

$$I_{sw}(t) = \frac{\sqrt{2}}{\sqrt{3}} \cdot U_{LL} \cdot \sqrt{\frac{C_{eq}}{L_{eq}}} \cdot e^{-\frac{R_{eq}}{2L_{eq}}t} \cdot \sin \frac{1}{\sqrt{L_{eq} \cdot C_{eq}}} \cdot t \quad (\text{dacă } \frac{L}{C} \gg \frac{R^2}{4}) \quad (5.29)$$

unde:

$$C_{eq} = \frac{C_j \cdot C_{tot}}{C_j + C_{tot}} \text{ este capacitatea echivalentă a circuitului;}$$

R_{eq} și L_{eq} – rezistența, respectiv, inductanța circuitului dintre condensatorul destinat conectării și condensatorul echivalent deja conectat;

U_{LL} - tensiunea (de linie) maximă.

Valoarea maximă a curentului de conectare (amplitudinea), $I_{sw \max}$ și valoarea I^2t se pot exprima în funcție de puterea reactivă maximă nominală a condensatorului destinat conectării, Q_j , și de puterea reactivă nominală a condensatorului echivalent:

$$I_{SW \max} = \sqrt{\frac{2}{3}} \cdot U_{LL} \cdot \sqrt{\frac{C_{eq}}{L_{eq}}} = \sqrt{\frac{2}{3} \cdot \frac{Q_j \cdot Q_{tot}}{(Q_j + Q_{tot}) \cdot X_{eq}}} \quad (5.30)$$

$$I^2 t_j = \int_0^{\infty} I_{SW}^2(t) dt = \frac{Q_j \cdot Q_{tot}}{3 \cdot (Q_j + Q_{tot}) \cdot R_{eq} \cdot \omega}$$

unde: $X_{eq} = \omega L_{eq}$ - reactanța echivalentă a circuitului.

Prin urmare, cele două restricții de amplasare a unei baterii BCS (j), impuse de conectarea acesteia într-un circuit care cuprinde și alte condensatoare (sau o rețea de cabluri subterană, cu capacitatea suficient de ridicată), sînt:

$$\sqrt{\frac{2}{3} \cdot \frac{Q_j \cdot Q_{tot}}{(Q_j + Q_{tot}) \cdot X_{eq}}} \leq I_{\max j} \quad (5.31)$$

$$\frac{Q_j \cdot Q_{tot}}{3 \cdot (Q_j + Q_{tot}) \cdot R_{eq} \cdot \omega} \leq I^2 t_{\max j}$$

Din expresiile (5.31) rezultă că pentru calculul restricțiilor de amplasare a unei BCS, este necesar de calculat parametrii fiecărui circuit echivalent de conectare "back-to-back": Q_{tot} , R_{eq} , X_{eq} . Acest lucru se efectuează prin reducerea circuitului de referință la nodul unde se instalează BCS respectivă.

Toate bateriile de condensatoare adiacente bateriei BCS analizate, instalate pe fiderii adiacenți și în stația de transformare, se conectează împreună într-un condensator echivalent, legat la bara de MT din stația respectivă. Acest condensator este pus în paralel și cu restul de BCS de pe fiderul unde este instalată bateria BCS analizată. În mod similar se calculează și rezistența și reactanța circuitului echivalent.

În continuare se dă un exemplu de determinare a parametrilor circuitului echivalent, în cazul amplasării a două BCS pe un fider. Pentru circuitul redat în Fig. 5.29 (b), avem:

- Q_0 este puterea reactivă totală a BC din stație și a BCS de pe fiderii adiacenți;
- $Z_{10} = R_{10} + jX_{10}$, $Z_{11} = R_{11} + jX_{11}$, $Z_{12} = R_{12} + jX_{12}$ sînt impedențele ramurilor comune și paralele de conectare a celor două BCS (de capacitate Q_1 și Q_2).

Expresiile parametrilor circuitului echivalent, necesare pentru calculul restricțiilor de amplasare a două baterii de condensatoare pe un fider de MT sînt date în Tabelul 5.13.

Tabelul 5.13. Expresiile parametrilor circuitului echivalent la conectarea a două BCS

Parametru	Q_{tot}	R_{eq}	X_{eq}
Prima baterie BCS	$Q_0 + Q_2$	$R_{11} + \frac{R_{10} \cdot R_{12}}{R_{10} + R_{12}}$	$X_{11} + \frac{X_{10} \cdot X_{12}}{X_{10} + X_{12}}$
A doua baterie BCS	$Q_0 + Q_1$	$R_{12} + \frac{R_{10} \cdot R_{11}}{R_{10} + R_{11}}$	$X_{12} + \frac{X_{10} \cdot X_{11}}{X_{10} + X_{11}}$

5.5.3. Metoda Algoritmilor genetici

Intrucît problema amplasării globale a BCS și calculul duratei de funcționare a BC și BCS, luînd în considerare toate restricțiile amintite mai sus, reprezintă o problemă de optimizare foarte complexă, soluționarea ei se va face utilizînd tehnica Algoritmilor genetici (AG), tehnică inspirată din principiul evoluției și care abordează cu succes astfel de probleme complexe de optimizare.

Structura de bază a AG utilizat pentru optimizarea amplasării BCS este, în principiu, cea prezentată în paragraful 2.4.2.

5.5.3.1. Funcția de adecvare

Pentru problema considerată, “cromozomii” reprezintă soluții de alocare a unui număr de baterii de condensatoare de diferite tipuri, după puterile nominale considerate, instalate pe F fideri, fiecare fider f avînd N_f posibilități de amplasare. Funcția obiectiv, în cazul nostru și funcția de adecvare a soluțiilor, are următoarea expresie matematică [Kalyuzhny 98], [Zisman 99/3]:

$$\Phi = C_{TOTAL} + k_1 \sum_{m=1}^M \sum_{i=1}^n \Psi(U_{mi}^2 - U_{\max}^2) + k_2 \sum_{m=1}^M \sum_{i=1}^n \Psi(U_{\min}^2 - U_{mi}^2) + k_3 \sum_{j=1}^K (I_{SW \max j} - I_{\max j}) + k_4 \sum_{j=1}^K (I^2 t_j - I^2 t_{\max j}) \quad (5.32)$$

unde:

$$\Psi(x) = \begin{cases} \Psi_0(x+1), & x > 0 \\ 0, & x \leq 0 \end{cases} \quad (5.33)$$

Ψ_0 - coeficient de penalizare suficient de mare;

$k_1, \dots, k_4$ - coeficienți de penalizare.

Pentru soluții care îndeplinesc toate condițiile impuse de restricțiile de tensiune și de conectare a bateriilor de condensatoare, funcția obiectiv este egală cu beneficiul total, C_{TOTAL} .

5.5.3.2. Structura programului de optimizare

Programul de optimizare de amplasare a BC și BCS pe partea de MT a stațiilor de transformare și pe fiderii de MT lucrează în două etape:

1. În prima etapă se calculează toți parametrii rețelei, fără baterii de condensatoare. Programul execută câteva calcule de circulații de putere pentru schema rețelei de MT, cu sarcini luate din curba de sarcină anuală clasată a transformatorului din ST. În urma acestor calcule se obțin valorile următorilor parametri:


- Sarcinile transformatorului din ST (active și reactive), la vârful de sarcină și la alte nivele de sarcină anuală alese;
- Pierderile de putere (activă și reactivă) la vârful de sarcină al celor trei elemente de sistem considerate: sistemul echivalent de transport, transformatorul din ST și fiderii alimentați de acest transformator;
- Pierderile de energie (activă) la vârful de sarcină al celor trei elemente de mai sus.

2. În a doua etapă, programul caută soluția optimală cu ajutorul algoritmului genetic descris în paragraful 2.4.2.

- Fiecare soluție dată de AG specifică mărimea bateriei BCS și numărul secției de pe fider unde urmează să se amplaseze această baterie.
- Fiecare soluție se determină în funcție de restricțiile impuse de păstrarea tensiunii în limite admise și de curentul de comutare permis.
- Pentru fiecare soluție se calculează beneficiile obținute din instalarea BCS alese, precum și costul acestor baterii.
- Soluția optimă se obține când valoarea funcției obiectiv Φ devine egală cu beneficiul total C_{TOTAL} .

Bibliografie


- [Alexandrescu 00] Alexandrescu, V., Cârțină, Gh., Bîrlădeanu, E. Grigoraș, Gh., Model multiobiectiv de optimizare a planificării rețelelor electrice de distribuție prin tehnici fuzzy, Contract de cercetare pentru SC. FDFEE Electrica Moldova S.A. Sucursala Iași, Nr. 562P/2000.
- [Alexandrescu 02] Alexandrescu, V., Cârțină, Gh., Grigoraș, Gh., Produs soft pentru planificarea și analiza rețelelor electrice de distribuție, Contract de cercetare pentru SC. FDFEE Electrica Moldova S.A. Sucursala Iași, Nr. 967P/2002.
- [Backes 97] Backes, J., Koglin, H.J., Klein, L., Network Planning under Economic Aspects with Special Regard to Reability, CIRED'97, 1997, Conference Publication No. 438.
- [Bonciu 00] Bonciu, Cl., Cârțină, Gh., Alexandrescu, V., Grigoraș, Gh., Abordari multicriteriale în modernizarea liniilor de MT, Simpozion Național de Rețele Electrice, 2000, Iași, Vol.II, pp. 305 - 309.
- [Blanchard 96] Blanchard, M., Delorme, L., Simard, C., Nadeau, Y., Experience with Optimization Software for Distribution System Planning, IEEE Trans. on Power Systems, 1996, Vol. 11, No. 4, pp. 1891 - 1897.
- [Boulaxis 02] Boulaxis, N.G., Papadopoulos, M.P., Optimal feeder routing in distribution system planning using dynamic programming technique and GIS facilities, IEEE Trans. on Power Delivery, 2002, Vol. 17, No. 1, pp. 242 - 247.
- [Brint 98] Brint, A.T., Hodgkins, W.R., Rigley, D. M., Evaluating Strategies for Reliable Distribution, IEEE Computer Applications in Power, 1998, Vol. 11, No. 3, pp.43-47.
- [Burke 00] Burke, J., Using Outage Data To Improve Reability, IEEE Computer Applications in Power, 2000, Vol. 13, No. 2, pp. 57 - 60.
- [Cabanel 96] Cabanel, J., Loi paysage et réseau électrique, Actes du Colloque International Lignes Electriques et Environment, 1996, Metz, pp. 91 -94.
- [Carer 97] Carrer, P., Martin, F., Pinget, A., Hamet, T., Journet, T., Dependability Approach Applied to Digital Protection and Control-Command Systems of EdF HV/MV Substations, EdF, DER, 1997, 97NR00027.
- [Cârțină 98/1] Cârțină, Gh., Alexandrescu, V., Poeată, A., Mușat, M., Optimal Planning of Distribution Networks Using Fuzzy Logic



Schema rețelei de transport 400/220 kV

ANEXA I

ANEXA 2



Schema rețelei de distribuție 20 kV

Tipar Digital realizat la **Tipografia pim**

Șoseaua Ștefan cel Mare nr. 11

Iași - 700498

Tel. / fax: **0232-212740**

e-mail: editurapim@pimcopy.ro

www.pimcopy.ro

About the book...

Electricity based innovation ranging from plasmas to microprocessors is essential for enabling sustained economic growth in the 21st century. The power systems are among the most complex system created by the mankind. These include hundreds of thousand components: generators, transformers, transmission lines, control and protection equipment and so on. Managing these systems will become increasingly difficult as overall loading continues to grow with deregulation. This book offers a systematic and thorough presentation of the basic principles of Artificial Intelligence, as well as numerous examples of applications related to main trends in monitoring and optimal control of power systems and it can be a useful reference for researchers in this field.

About the authors ...

Gh. Cârțină (Member IEEE) received the M. SC. And Ph. D. degrees in Electrical Engineering from Technical University "Gh. Asachi" of Iasi, Romania, in 1964 and 1972 respectively. He is currently professor in the Department of Power Systems of Electrical Engineering Faculty at the same university. His research interests include especially Artificial Intelligence's applications to monitoring and optimal control of power systems.

Gh. Grigoraș received the M. SC. degree in Electrical Engineering from Technical University "Gh. Asachi" of Iasi, Romania, in 2000. His research interests are fuzzy techniques and their application to power systems.

ISBN: 973-86764-4-4